

行政院原子能委員會
委託研究計畫研究報告

智慧型微型電網最佳化用電需量與能源配置比例估測機制
**Optimal forecasting mechanism of electricity demand and energy
capacity installation ratio for intelligent micro grid**

計畫編號：1002001INER065

受委託機關(構)：元智大學

計畫主持人：魏榮宗

聯絡電話：(03)463-8800 ext:7117

E-mail address：rjwai@saturn.yzu.edu.tw

核研所聯絡人員：何元祥

報告日期：100 年 12 月 6 日

目 錄

中文摘要.....	2
英文摘要.....	4
壹、計畫緣起與目的.....	6
貳、研究方法與過程.....	29
(一) 建立再生能源數學模型.....	29
(二) 建立混合能源裝置容量最佳化模擬機制.....	55
(三) 負載需量估測.....	70
參、主要發現與結論.....	103
肆、參考文獻.....	106

中文摘要

由於天然資源缺乏，台灣大部分的能源必須仰賴進口，不僅成本較貴且受國際市場波動影響及控制，近年來因經濟快速的發展，導致台電系統發電量不足而造成限電的危機，加上近年來環保意識抬頭，結合再生能源之智慧型微型電網之發展成為目前相當熱門研究主題之一，智慧型微型電網是屬於分散式發電系統，其設備容量一般較小，大部分會與電力公司配電系統併聯，其系統可利用再生能源協助供電達成環保效益，其最主要可在台電系統發電量不足或是故障時，提供特定負載之緊急用電，該系統與電力公司配電併聯後對於整個電力可靠度、供電品質以及能源效率有正面影響，而如何決定智慧型微型電網所供應特定負載之用電需量以及系統內部各種能源之配置比例，使其能夠同時達到最佳經濟效益與用電效率是目前急須解決之課題。本計畫將以實驗廠址進行實測，以驗證本計畫所發展策略之有效性。本計畫預期可達到五點目標：第一點，將過去歷史資料做分析比對整理，找出與用電需量關聯性較大的變因，一來可降低估測所需資料量，二來當估測系統參數有大幅變動時，依然可達到準確的估測效果；第二點，本架構搭配運用粒子尋優最佳化(Particle Swarm Optimization)演算法不斷的調整估測機制參數值，除可縮短運算收斂時間之外，局部最佳解問題亦可有效被處理；第三點，本架構可適用於短期、中期以及長期用電需量估測，

亦可針對不同的估測系統進行需求設計；第四點，建立再生能源動態模型並透過當地氣候資訊找出各種能源之容量因子，評估各種能源在設置場址實際發電效益；第五點，透過裝置成本及回收成本之計算，找出最符合經濟效益之系統設置黃金比例。

英文摘要

Because of the lack of natural resources, most energy used in Taiwan imports from overseas. Not only the cost is expensive, but also it is influenced and controlled by international market. Due to rapid economical development in recent year, it results in insufficient generating power produced by Taiwan Power Company to cause the power restricted crisis frequently. Besides, the environmental awareness has received more attention recently, and the development of intelligent micro grid with renewable energy generation systems is one of important research topics. The intelligent micro grid belongs to a distributed power generation system. Its power capacity is smaller than a conventional power plant and is usually operated in parallel with the power company. This framework use renewable energy generation systems to supply power for achieving environmental protection benefit. The main function is to supply the backup emergent power for specific load as power outage. This system is operated in parallel with the power company to have the positive impact on power reliability, power quality and energy efficiency. How to determine the electricity demand and what is the optimization ratio of energy capacities in the intelligent micro grid to achieve the optimal economic benefit and power utilization efficiency are urgent issues to resolve. The effectiveness of the proposed strategy in this project is verified by an experimental case study. The project is aimed to achieve the following five targets: (1) It analyzes historical data of a real case to find the important correlation factor with the power demand for reducing the requirement of data quantity and achieving precise forecasting performance even under serious system uncertainties. (2) The proposed strategy uses the particles-swarm optimization

algorithm (PSO) to adjust forecasting parameters for not only reducing convergent time and but also saving the problem of local optimum. (3) The proposed strategy can be applied to short-term, medium-term and long-term load forecasting according to different installation environment. (4) The dynamic models of renewable power generation systems are built for calculating the capacity factor according to the weather information, and assess the generation efficiency of each renewable power generation system for specific installation location. (5) According to the calculation of installation cost and recovery cost, the optimization ratio of the installation capacity for each renewable energy source can be obtained.

壹、計畫緣起與目的

由於全球氣候變遷問題日益升高，各國家紛紛提倡低碳經濟，以節能減碳為核心，進行能源使用效率提升，並發展可再生能源。風力以及太陽能光電池發電系統是目前技術開發最成熟之再生能源，燃料電池近年來也展現了其未來發展潛力[1]-[3]。

太陽能光電池發電系統其特點為無放射性的污染，並有耐用且維修費低的優點，而且在其轉換效率提升以及半導體工業大幅躍進的影響下，其成本持續降低，使其逐漸接近經濟實用化；以風力發電來說，其沒有污染且不會破壞臭氧層，一些風力資源豐富之國家均已大量開發，目前也越來越受到支持及重視；燃料電池發電系統的優點主要包括有高效率、幾乎是零污染以及架構彈性等，這類再生能源之研發技術近年來也持續快速發展中。

然而上述所列之能源在發展技術上都尚有其各自缺點有待克服，例如太陽能光電池以及風力發電量相當依賴天氣的狀況[4]，而燃料電池則是發電成本昂貴，因此當今傳統電力系統面臨諸多挑戰，例如現行離線方式之應變計畫存在著連鎖停電的風險、再生能源與新能源發電的不穩定及開發中國家人口成長速度遠高於電網的建置速度等。面對以上挑戰，世界各國之電源供應系統逐漸由集中式電源朝向分散式電源發展，推廣靠近用戶端且容量小之分散式電源並且引進新能源，作為傳統大型集中式供電系統之輔助性及替代

性電力。

分散式能源的優勢在於容易尋覓設置地點、設備投資靈活度高、易應付尖峰負載狀況、可作為孤島運轉或緊急發電電源、較高的綜合能源利用效率、較低的故障率、管理容易、可利用低碳能源及減少輸變電與配電線路設備的投資。為對抗全球氣候變遷，先進國家紛紛研擬溫室氣體減量目標，降低石化能源使用比例，擴大再生能源利用，提高能源的利用效率，降低能源密集度。然而再生能源及新能源發電的不穩定特性，當其併入電網之容量佔比逐步提高而達到某個程度時，其將影響大電力系統的穩定度，需發展即時有效監控/調度分散式或再生式電源技術，降低分散式能源併網帶來的衝擊，因此美國、歐洲與日本等先進國家近年都積極投入智慧電網技術研究。

智慧型微型電網是屬於分散式發電系統，其由許多小型模組化的發電系統和對應之配電系統所組成，這些系統大部份設置在電力需求所在地，除了能獨立運作外，也可併聯電力網路，例如燃料電池、汽電共生、太陽光電、小型風力發電與生質能發電等都可視為分散式發電系統。而傳統的電力多是使用化石燃料(煤炭、石油、天然氣)、水力及核能發電等大型集中式發電系統所產生，再從供應端透過電力網路長距離輸送後配送至負載端，系統僅能單向傳輸電力。這樣的系統有其缺點，例如對輸入燃料的依存度高、溫室氣體

和其他污染物對環境的影響、輸配電損失、需要電力配送與交換設備等，相較於傳統的電力系統，分散式發電系統具備許多優勢。微型電網由於多設置於電力需求所在地，可減少電力輸配損失和成本(電力輸配成本約占總電力成本的 30%)，並可延緩電網電力傳輸負荷成長，延後電力輸配電系統升級或增建的時程。相較於集中式電廠，燃料電池、生質能或燃油發電機等分散式發電系統在發電過程中所產生的廢熱可透過結合熱電共生系統，提高系統整體效能。供電中斷時，微型電網則可對家庭或鄰近區域，利用儲存電力在一定時間內持續供電。

從電力投資者的觀點而言，分散式發電系統有其誘因，例如較易覓得開發地點，且短期內即可生產電力出售，可較快速的回收投入成本。資金利用方面，分散式發電系統可視電力需求逐步投入資本，因此在資金的利用效益與風險上都較集中式電廠有利。在未來台灣可能自由化的電力市場中，分散式電力的供應者可充份利用電價獎勵條件，提升其競爭力，例如在離峰時購入電力，然後在電力需求高峰時賣出，因此分散式電力系統可視為對於電力價格波動之實體性防範措施。當然，再生能源和其它分散式電力系統(例如燃料電池等)的運用，有助於降低能源進口量及提升電力供應安全，促進能源供應的多元化。

本計畫所提出之智慧型微型電網係以太陽能光電池發電系統、

風力發電系統以及燃料電池作為分散式電源實施例，而由於環保意識抬頭以及溫室效應所帶來之二氧化碳汙染問題，全世界正積極推廣及發展再生能源，將來各種再生能源發電系統技術開發都將日臻成熟，因此本計畫所提出之智慧型微型電網之架構除了上述所提出技術已開發成熟之太陽能光電池發電系統、風力發電系統以及燃料電池之外，未來包括潮汐發電、水力發電、地熱以及生質能等其他再生能源也將可彈性加入本計畫所提出之智慧型微型電網中，除了再生能源以外，根據不同設置廠址之需求，本計畫所提出之智慧型微型電網也可搭配如柴油引擎以及火力發電等傳統能源，此智慧型微型電網架構將不侷限於某幾種特定能源，而是根據不同設置場址之實際需求建構出最適合當地場址且多元化組合之混合能源發電系統。

本計畫所提出之「智慧型微型電網最佳化用電需量與能源配置比例估測機制」研擬利用過去的歷史資料做統計分析，找出與用電需量有較大關聯性的可能變因(例如過去的用電資料和環境溫度等)以降低估測所需資料量，將其可能變因輸入以模糊類神經網路(Fuzzy Neural Network)以及粒子尋優最佳化(Particle Swarm Optimization)演算法為基礎之智慧型用電需量估測機制，以達到預設估測效果，並利用場址評估找出設置場址實際可安裝該系統之大小，接著建立再生能源動態模型及運用當地氣候資訊找出各種能源之容量因子[5]，

找出容量因子是考慮各種能源在當地之發電效能以及該裝置多少容量方能穩定提供足夠電量予負載端，根據上述條件，計算其裝置成本以及每年回收費用，包括超約罰款、流動電費、基本電費與二氧化碳減量費用等，透過回收年限計算機制找出回收年限最短之年份，而該比例即為智慧型微型電網系統內部能源裝置容量黃金比例，達到可提供負載端穩定電力以及最短回收期目標，達到決定智慧型微型電網所供應特定負載之用電需量以及系統內部各種能源之配置比例，使其能夠同時達到最佳經濟效益與用電效率。

智慧型微型電網所供應特定負載之用電需量估測方式主要可分為短期、中期以及長期估測，有許多統計學的回歸法及演算法運用在用電需量的估測上，但各有其缺失有待改善，回歸法較常運用於用電需量估測的包括有自回歸移動平均法、線性迴歸法、或然時間序列以及指數平滑法等[6]，缺點為無法處理其輸入負載以及其影響因子間的複雜非線性關係，例如平日跟假日的用電特徵、特殊事件以及氣候的相關特性等，都可能對用電需求造成出乎意料的大變化。而傳統基因演算法(Genetic Algorithm)、演化式計算(Evolutionary Programming)、模擬退火演算法(Simulated Annealing)、等雖然可處理複雜的非線性問題，則常發生運算收斂時間較長以及容易落入局部最佳解的問題，人工智慧法對可以處理非線性之問題，相較於傳統方法具有較佳之估測能力，因此現今有許多智慧型控制方法被發

展於用電需量估測，其中模糊理論(Fuzzy Theory)和類神經網路(Neural Network)是最常見的，以下針對此兩種人工智慧法做簡單介紹：

模糊理論

模糊理論是為了解決真實世界中普遍存在的模糊現象而發展的學問，它是由美國自動控制學者 Zadeh 於西元 1965 年首先提出的定量表達工具[7]-[9]，用來表現某些無法明確定義的模糊概念，尤其在表現人類語言特有的模糊現象方面具有頗佳的成果。因為現在的數位電腦所沿用的「1/0」二值邏輯(Binary Logic)，只能表示非此即彼的明確概念，卻很難處理亦此亦彼或無法明確定義的模糊概念。換句話說，除了一些像「男」與「女」這類本身就可以明確劃分的事物之外，人類大部分的知識或大部分用語言表達的概念不易以二分法的方式順利的處理。人工智慧(Artificial Intelligence, AI)的目標，是希望把電腦從單純的數值計算的角色擴展到能夠模仿人的知識思維，但是畢竟電腦是依循傳統二值思想建立的數學模型，本質上就不善於處理人類特有的模糊性思維方式。當模仿人類執行控制命令的時候，要將模糊的控制知識變成數學的模式是相當困難的，尤其要將熟練的操作員心中所使用的控制法則，轉換成電腦程式而達到自動化目的更是困難，因為要將操作者的經驗變成數學模

式時，將面臨許多的突發狀況以及應付訣竅。再者，這些操作者的經驗多是用在日常生活的用語敘述，日常生活中所說的話通常是非常模糊的，也就是說，對於某些事情的看法上並沒有明確的標準，亦即所謂的模糊，而模糊理論的重點就是要建立數學模型，能夠吸取人腦處理模糊事物的特點，把人的知識經驗描述出來，以便將來能夠將其運用於電腦，在人腦與電腦之間架設溝通的橋樑，而模糊理論便在這種情況下被提出，其將傳統數學從二值邏輯擴展到連續多值(Continuous Multi-Value)，利用歸屬函數(Membership Function)描述概念的特質，亦即使用零和一之間的數值來表示一個元素屬於某一概念的程​​度，這個值稱為元素對集合的歸屬度(Membership Grade)。當歸屬度為一時，表示該元素百分之百屬於這個概念；當歸屬度為零時，則表示該元素完全不屬於這個概念；介於兩者之間的就是完全屬於和不完全屬於之間的灰色地帶，這也就是模糊化過程，而模糊理論便藉此去學習人類特有之思維方式[10]-[12]。




圖 1 模糊控制動態訊號分析

針對模糊控制而言，是以對系統的操作法則代替對系統作精確的數學模式描述，如圖 1 所示，經由系統輸出迴授控制，反覆進行

系統誤差的修正，以得到合乎要求的控制結果，此即為模糊控制的主要優點，所以它是以經驗法則與常識判斷來作為控制的主要依循。換言之，操作人員並非經由精確數學描述的角度去瞭解受控系統，而是根據經驗和直覺去判斷適當的控制命令，因此可以巧妙的駕馭複雜的控制系統，此種控制方法可以視為探索式的決策規則，若將這些操作人員腦中的實踐經驗加以總結和描述，使用語言表達成定性的條件語句及所需的決策規則，然後利用模糊數學為工具使其定量化，進而設計出控制器來實行人的經驗，即可模仿人類的思維方式及操作策略，致使控制器代替人類對複雜的受控系統進行控制。模糊邏輯控制系統之基本架構如圖 2 所示，其輸入通常是明確值(Crisp)而非模糊值，輸出也必須是明確值才能對受控系統發生作用。但模糊控制器是以口語化的控制規則為其主體，為了能夠把輸入的明確值與語言化的控制規則結合，必須把輸入的明確值作模糊化(Fuzzification)處理，以便對應到模糊邏輯控制之語言變數的論域範圍中；同理，經過模糊規則庫推論出來的結果是對應到輸出語言變數的論域範圍中，也必須再做解模糊化(Defuzzification)處理，才能應用到實際的受控系統。

總結可知，模糊邏輯控制器是由下列四個主要功能系統搭配所要處理的控制系統組合而成的[7]。

一、 模糊化介面(Fuzzification Interface)

- (一) 接收資料擷取介面(Data Acquisition Interface)所量測的值。
- (二) 進行量化(Quantization)工作，以便將觀測量的範圍轉換到語言變量對等的論域。
- (三) 將輸入資料轉換成可被模糊集合表現的語言數值。

二、模糊知識庫(Fuzzy Knowledge Base)

包括應用領域的知識和參與控制的目標，主要由控制規則庫及資料庫所組成。

- (一) 控制規則庫(Control Rule Base)：利用各種方法定義出來的語言控制規則，用來描述控制目標和領域專家的控制策略。
- (二) 資料庫(Data Base)：提供語言變數所需的定義，例如變數論域、語言項子集合及歸屬函數的規劃等，以方便提供給語言控制規則和模糊邏輯控制中的模糊資料管理。

三、決策邏輯單元(Decision Making Unit)

此為模糊推論(Fuzzy Inference)機構，具有模仿人類作決策判斷的能力，根據人類特有的近似推理方式，所延伸的模糊推論技術的計算機構。

四、解模糊化介面(Defuzzification Interface)

轉換推論輸出之模糊結果成明確輸出值，可產生實際明確的控制動作。

由上述之說明可歸納出模糊控制系統的基本設計步驟，其說明

如下[7]：

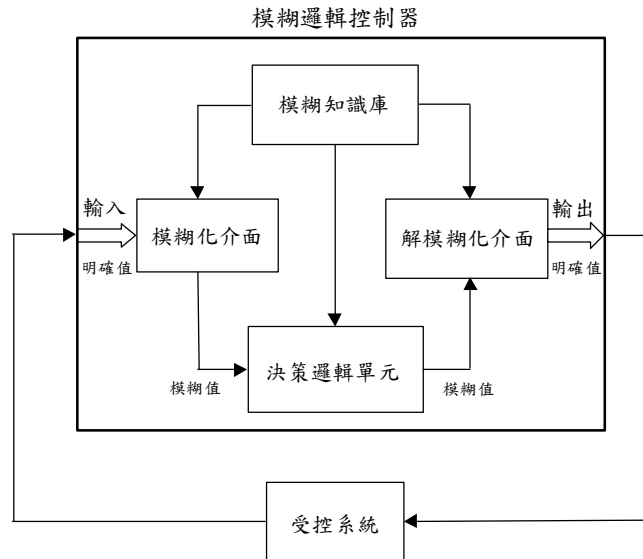


圖 2 模糊邏輯控制基本架構

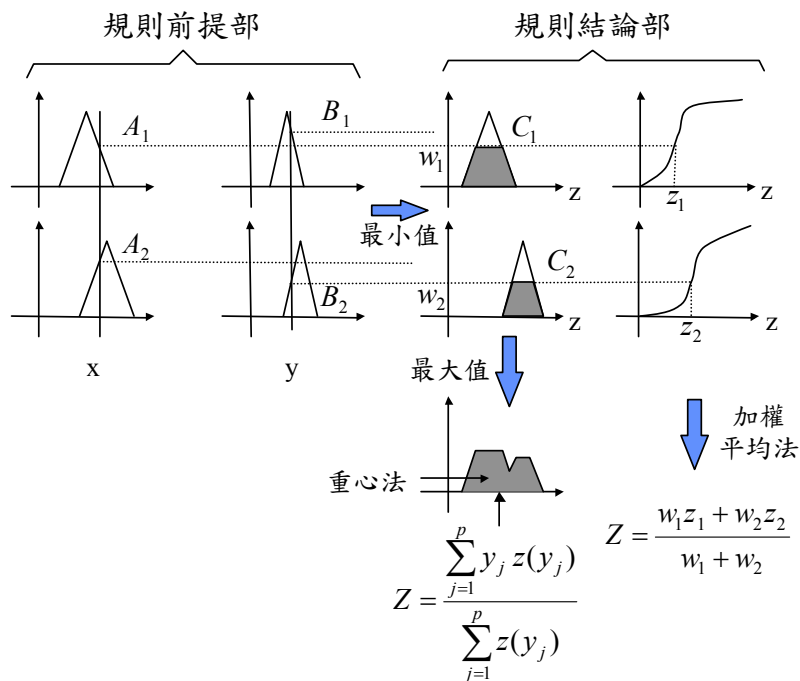


圖 3 模糊推論機構

步驟一：定義輸入與輸出變數

首先探討控制系統的特性，尋求有意義之狀態加以觀測作為控制器的輸入變數，同時尋求所需的控制動作當做輸出變數。

步驟二：定義模糊變數與歸屬函數

此步驟設定各變數模糊化的條件。根據實際情況考量輸入與輸出變數的觀測值分佈範圍，來決定各個變數之論域(Universe of Discourse)，將其劃分成適當數量之模糊區域，再定義模糊變數(Fuzzy Variable)和其對應的歸屬函數以涵蓋變數的分佈空間，使得任意之明確變數值皆可被模糊化，亦即可以適當的歸屬值表示其屬於某一模糊集合變數的程度。

步驟三：訂定控制規則

設計者可依據專家的工作經驗、控制知識與系統之動態特性等，擬定適合的控制策略，而以語言化的條件句撰寫成控制規則。

步驟四：訂定模糊推論的方法

模糊推論或稱為近似推論，乃是將模糊輸入變數轉換成模糊輸出變數的推論演算程序，此為模糊控制之核心。

步驟五：定義解模糊化的方式

模糊推論完成之模糊輸出變數轉換為明確值之過程，即為解模糊化。基本上，解模糊化是一種求取平均分佈的演算法，常用

之方法有重心法(Center of Area Method)及加權平均法(Weighted Average Method)，如圖 3 所示。重心法是求推論結果的陰影面積重心，並以其對應的元素為輸出操作量；加權平均法是以歸屬度為加權係數，其最後輸出是每個控制規則輸出的加權平均，此種方法考慮各元素之貢獻，對模糊控制而言具有改善系統響應的優點。

由上述介紹可瞭解模糊理論的基本精神為接受模糊現象存在的事實，而以處理概念模糊不確定的事物為其研究目標，並積極的將其嚴密的量化成電腦可處理的訊息。模糊理論的應用較偏重於人類的經驗及對問題特性的掌握程度，不主張用繁雜的數學分析來解決問題，也就是說傳統的集合論是立場鮮明，而調和包容則是模糊理論的基本精神。

類神經網路

大約西元 1800 年，藉由解剖學的幫助以及之後神經電化學家 E.D.Adrian 實驗中所發展之神經細胞電化學作用學說，使人們瞭解神經細胞的作用，並影響了日後人工神經元模型的建立。西元 1943 年 McCulloch 與 Pitts 於 “A Logical Calculus of Ideas Imminentin Nervous Activity” 一文中提出神經元數學模型(MP 模型)，其對後來的類神經網路架構具有啟發作用。西元 1949 年 Hebbian 提出了神經

細胞的學習規則[7, 8, 13]，其規則描述為「當人腦在學習不同事物時，每個細胞的連結隨時都在改變，如果一個腦細胞受到另一個腦細胞連續的作用時，它們之間的連結力量就會增強」，此學習規則引導了日後類神經網路的發展。類神經網路便是藉由模仿人類腦部活動所發展出來的模型，西元 1957 年由 Rosenblatt 提出之感知機模式逐漸發展而成，就網路架構而言，它是由許多簡單而互相連接的處理單元(Processing Elements)，也就是神經元(Neurons)所組成；就網路的功能而言，它是一種由生物模型所產生出來的新型態資訊處理與計算方式[7, 8, 13]。

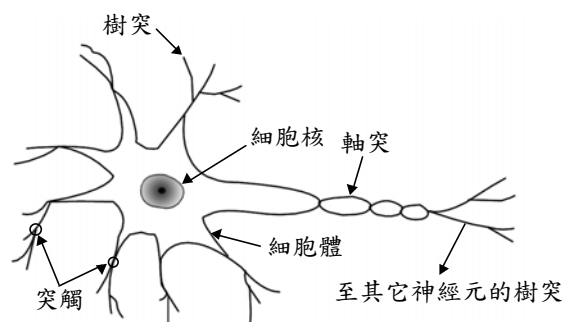


圖 4 神經元生物模型

人的大腦大概是由 10^{11} 個神經元所組成的龐大組織，典型的神經元生物模型如圖 4 所示，其包含了細胞體(Soma)、軸突(Axon)、樹突(Dendrites)和突觸(Synapse)等部分，其詳細介紹如下[7, 8, 13]：

- 一、細胞體：是由細胞核、細胞質和細胞膜所組成，當激勵(Excitatory)作用發生時，細胞膜的電位會增加，而當抑制(Inhibitory)作用發生時，細胞膜的電位會降低。

- 二、 軸突：是一種由細胞體向外延伸的神經纖維，將細胞體的脈波傳送到其它神經元。
- 三、 樹突：樹突可分為兩種—輸入樹突及輸出樹突。圖 4 中左側接到細胞核的樹突是用來接收其它神經元傳來的信號，稱為輸入樹突；而圖 4 右側接到軸突的樹突是用來傳送信號至其它神經元，稱為輸出樹突，因此樹突可以說是神經元呈樹枝狀的輸出入機構。
- 四、 突觸：訊號的傳送是透過軸突與樹突，而連接軸突與樹突的介面即是突觸，每個神經元大約有 $10^3 \sim 10^4$ 個突觸。突觸是神經網路上的記憶體，它表示兩個神經元間的連結強度，在此將此連結強度以數值來表示，並稱之為鍵結值(Connection)。




圖 5 人工神經元模型

一般而言，當神經網路在進行學習時，外界刺激神經元所產生的電流會改變突觸上的鍵結值；學習過程中，外界刺激所產生的電

流反覆在神經網路上流動，突觸上的鍵結值也反覆的在改變，最後慢慢的趨向於穩定，此時即表示學習已告完成。而類神經網路理論便是根據這些生物模型特性所發展而來。

綜合前段所述，當神經元透過輸入樹突由其它神經元輸入脈波訊號後，經過神經細胞核的處理，其處理動作是將所收集之訊號作加總，經非線性轉換後，產生新的脈波訊號，如果輸入訊號夠強，則新的脈波訊號會經由軸突送到輸出樹突，再透過突觸將此訊號傳給其它神經元。值得注意的是，當訊號經過突觸後，由於突觸鍵結值的影響，其訊號大小值亦會改變。藉由仿造上述神經元的生物模型，可以得到人工神經元的運算模型，如圖 5 所示。此模型之中，神經元又稱處理單元或節點(Node)，它的輸入端相當於生物模型中的樹突，而它的輸出端相當於生物模型中的軸突，至於鍵結值，又稱神經鍵或權重值(Weight)，則相當於生物模型中的突觸。描述圖 5 中訊號的傳遞，假設由神經元 i 到神經元 j 的鍵結值為 W_{ji} ， x_i 為神經元 i 的輸出訊號，亦為神經元 j 的輸入訊號，則傳遞到神經元 j 的訊號為

$$net_j = \sum (W_{ji} x_i) + \theta_j \quad (1)$$

其中 net_j 表示為神經元 j 的淨輸入， θ_j 表示神經元 j 的臨界值(Threshold)或偏權值(Bias)，即輸入訊號的加權乘積和必須大於偏權

值後，才能被傳輸至其它人工神經元中，而整個神經元的輸出為

$$y_j = Q(net_j) \quad (2)$$

其中 y_j 為神經元 j 的輸出訊號以及 $Q(\cdot)$ 為線性或非線性轉換函數。

一般神經元所採用的非線性作用函數或激發函數(Activation Function)包含了以下幾種常見的函數：

一、雙值激發函數(Bipolar Activation Function)

$$Q(net) = \begin{cases} 1 & \text{對於 } net \geq 0 \\ -1 & \text{對於 } net < 0 \end{cases} \quad (3)$$

或二元激發函數(Binary Activation Function)

$$Q(net) = \begin{cases} 1 & \text{對於 } net \geq 0 \\ 0 & \text{對於 } net < 0 \end{cases} \quad (4)$$

二、飽和激發函數(Saturation Activation Function)

$$Q(net) = \begin{cases} sat1 & \text{對於 } net > sat1 \\ net & \text{對於 } sat1 \geq net \geq -sat2 \\ -sat2 & \text{對於 } net < -sat2 \end{cases} \quad (5)$$

三、斜坡激發函數(Ramp Activation Function)

$$Q(net) = \begin{cases} net & \text{對於 } net \geq 0 \\ 0 & \text{對於 } net < 0 \end{cases} \quad (6)$$

四、Sigmoid 激發函數

$$Q(net) = \frac{1}{1 + \exp(-\beta \cdot net)} \quad (7)$$

其中 $\beta > 0$ 且 $Q(\cdot)$ 是單調遞增函數。

或雙曲正切函數(Hyperbolic Tangent Function)

$$Q(net) = \frac{1 - \exp(-\beta \cdot net)}{1 + \exp(-\beta \cdot net)} \quad (8)$$

其中 $\beta > 0$ 且 $Q(\cdot)$ 也是單調遞增函數。

五、高斯激發函數(Gaussian Activation Function)

$$Q(net) = \exp\left[-\frac{(\|net - W\|)^2}{S^2}\right] \quad (9)$$

其中 S^2 為 $\|net - W\|$ 之變異數(Variance)。

六、放射基底函數(Radial Basis Function, RBF)

$$Q(net) = \frac{\exp[-(net - m)^2]}{S} \quad (10)$$

整個網路的特性與激發函數的選取息息相關，所以不同性質的網路選用不同的激發函數。緊接著在此針對類神經網路的特性做一說明，一般而言，類神經網路具有下列特性[7]：

- 一、 平行處理：類神經網路採用平行計算，經由許多不同的人工神經元來做運算處理，有別於傳統的范紐曼式(Von Neumann)電腦。
- 二、 錯誤容忍度：類神經網路運作時具有高錯誤容忍程度，如果輸入資料混雜少數的雜訊干擾，仍然不會影響其運作的正確性，而且即使有部分人工神經元失效，整個神經網路依然能夠有效運作。
- 三、 聯想記憶(Associative Memory)：回歸型類神經網路中，並沒有所謂的資料記憶區，但是網路卻可以記住需記憶的訓練範

例，爾後若對其輸入訊號進行運算，整個網路藉由運算過程可聯想出相對應的輸出值。此種記憶方式稱為聯想式記憶，而它的聯想過程稱為內容定址(Content Addressing)，以別於目前數位電腦所採用的記憶體位址定位。

- 四、 解決最佳化問題：是指在一問題領域中，希望找到一組設計變數值，使其在滿足設計限制條件下，致使整個設計目標達到最佳化狀態。
- 五、 超大型積體電路實現(VLSI Implementation)：類神經網路具有高度的互連性(Interconnection)，不但結構簡單且具有規則性，易以超大型積體電路來實現。

介紹完類神經網路的基本架構及運作模式後，最後將依類神經網路的特性做一分類。目前著名的類神經網路模式不下數十種，下面將類神經網路之應用依其特性分成下面四大類[13]：

- 一、 監督式學習網路(Supervised Learning Network)：從問題領域中取得訓練範例，包含輸入變數以及輸出變數，並從中學習輸入變數與輸出變數的內在對映規則，以應用在只有輸入變數時而需要推論其輸出變數時之新案例。分類應用與預測應用屬之。
- 二、 非監督式學習網路(Unsupervised Learning Network)：從問題領域中取得訓練範例，只有輸入變數，並從中學習範例的內

在聚類規則，以應用在只有輸入變數時而需討論它與哪些屬於同一聚類之新案例。

- 三、 聯想式學習網路(Associate Learning Network)：從問題領域中取得訓練範例(狀態變數值)，並從中學習範例的內在記憶規則，以應用在只有不完整的狀態變數值時，而需要推論其完整的狀態變數值之新案例。資料擷取與雜訊過濾應用屬之。
- 四、 最佳化應用網路(Optimization Application Network)：對一問題決定其狀態變數值，使其在滿足設計限制條件下，致使設計目標達到最佳狀態的應用。設計應用與設計排程應用屬之，此類設計應用的網路架構大都與聯想式學習網路的架構相似。

一般運用人工智慧法時都會搭配一訓練演算法，以達到最佳估測效果，其中最常見的演算法有包括倒傳遞演算法(Back-propagation Algorithm)、基因演算法(Genetic Algorithm)、演化式規劃法(Evolutionary Programming)、模擬退火法(Simulated Annealing)、演化式策略法(Evolutionary Strategy)、遺傳規劃法(Genetic Programming)、微分演化法(Differential Evolution)和進化式演算法(Evolutionary Algorithm)等，在此針對以上提到的常見演算法做簡單介紹：

一、倒傳遞演算法

目前類神經網路學習模式中，最具代表性且應用最普遍的學習模式之一。倒傳遞類神經網路的架構為多層感知器配合誤差倒傳遞演算法為學習演算法，屬多層前饋式網路，是以監督式學習方式處理輸入輸出間的非線性映射關係，達到準確分類的效果，但其容易掉入區域最小解且無法有效收斂至鄰近區域最小解的困難。

二、基因演算法:

基因演算法是取於大自然的一種演算法，利用競爭-生存以及基因交換-突變，尋求問題的正確解答。但其運算時間較長且較容易落入局部最佳解，此外其編碼以及解碼結構也相當複雜。

三、演化式規劃法:

演化式計算是人工智能研究領域的一項學科，原理大都來自於自然界生物演化的機制，依其發展特性來分類，演化式規劃則是介於數值分析和人工智能間的方法與模型。其缺點為當演化式規劃收斂接近最佳解時，其收斂速度會變慢。

四、模擬退火法:

模擬退火演算法簡單來講是一種 optimizing brute-force search 的演算法，當遇到一個沒有辦法直接找出答案的問題，就靠檢查每一組可能的組合是否為答案，optimizing 則是在各答案中(盡量)選取最佳的答案，這種方法是很容易可以執行的。不過其算是徒法煉鋼的一種方法，且若其流程中有步驟錯誤或是微調值不理想，會對結果

造成很大的影響。

五、演化式策略法:

演化式計算是人工智能研究領域的一項學科，原理大都來自於自然界生物演化的機制，依其發展特性來分類，演化式策略則是屬於數值分析的方法與模型。

六、遺傳規劃法:

演化式計算是人工智能研究領域的一項學科，原理大都來自於自然界生物演化的機制，依其發展特性來分類，遺傳規劃則是偏向以程式表現人工智能行為的方法與模型。

七、微分演化法:

演化式計算是人工智能研究領域的一項學科，原理大都來自於自然界生物演化的機制，依其發展特性來分類，微分演化法則是用於多值域及多目標工程最佳化的方法與模型。

八、進化式演算法:

進化式演算法是以整個樣本空間為基礎，在演化的過程中個體會互相影響(交換訊息)，進化式演算法交換訊息主要是透過選擇、競爭和重組三個步驟所組成。

綜合觀察先前技術，過去常見的人工智慧型理論(模糊理論以及類神經網路)各有其缺點，模糊理論由於是以口語方式表達，因此可以不需要預先知道受控系統的物理模型，再加上規則庫內有許多人

性化且易於瞭解的規則可遵循，因此容易被人們所接受。但是訂定完整的規則庫相當困難，若規則訂定不佳則對系統控制性能影響十分嚴重。如果此系統又是未知系統，那要訂定完整的規則庫更是難上加難。而類神經網路可以不必預先知道受控系統的數學模型，因為其具有強大的學習能力，對於任何的未知系統都能根據線上調整類神經網路的連結權重值，以達到所期望之鑑別與控制性能。但是所調整出來的連結權重值所代表的意義，並不能像模糊控制器的規則庫能以口語方式來表達，因此類神經網路控制器並不容易被人們瞭解其控制規則。

而過去常見與人工智慧型法搭配的訓練演算法也都各有其缺點，例如基因演算法運算時間較長且較容易落入局部最佳解，其編碼以及解碼結構也相當複雜，演化式規劃收斂接近最佳解時其收斂速度會變慢，模擬退火法算是徒法煉鋼的一種方法，且若其流程中有步驟錯誤或是微調值不理想，會對結果造成很大的影響，而最傳統也最常見的倒傳遞演算法則容易掉入區域最小解且無法有效收斂至鄰近區域最小解。

過去文獻中，曾有專家學者提出將過去用電資料分成用電趨勢以及用電變化量[16]，利用其過去用電特性並且搭配類神經網路預估用電需量，但當其估測系統參數有大幅變動時(例如新增建築物或設備增設)，其估測準確度將大受影響。也有其他文獻分別提出利用類

神經網路搭配粒子群優化演算法做短期用電需量估測[17, 18]以及模糊理論運用於中期用電需量估測[19]，並與傳統之統計學回歸法以及類神經網路搭配傳統的訓練演算法做比較，都驗證其比傳統估測方式具有較佳之估測性能，但如同上述所提到，傳統模糊理論及類神經網路架構都還是有其缺點，根據台電公司有關超約用電的規章，當用戶之最高需量超出部分在契約容量 10%以下，按二倍計收基本電費，超出部分在契約容量 10%以上，按三倍計收基本電費，不精確的估測結果除了增加用電成本之外，也將會影響其用電可靠度，因此本計畫研擬將模糊理論與類神經網路架構做結合，利用模糊類神經網路架構搭配粒子群優化演算法做需量評估，同時結合兩種人工智慧型預測法之優點以及粒子群優化演算法的最佳化特性做用電需量估測以達到最佳之經濟效益以及用電可靠度，而至於智慧型微型電網系統內部各種能源配置最佳比例，過去有許多文獻提出考慮各種能源不同之裝置型號，找出成本最低之組合[20]，但其缺點並未考慮設置場址實際發電效率以及場地等限制因素，並無法貼切的根據設置場址實際環境做出最佳比例之配置，本計畫「智慧型微型電網最佳化用電需量與能源配置比例估測機制」主旨係以上述所列缺失，逐一克服達成最佳經濟效益與用電效率之目的。

貳、研究方法與過程

一、 建立再生能源數學模型

本計畫主要目的在於決定智慧型微型電網所供應特定負載之用電需量以及系統內部各種能源之配置比例，使其能夠同時達到最佳經濟效益與用電效率。首先將透過建立各種再生能源之數學模型，找出每一種再生能源的容量因子，了解每種能源在設置場址之實際發電效益，以利更進一步做最佳化評估。

(一) 建立太陽能數學模型

太陽能板主要由許多太陽能電池單體經由串、並聯後再加上增加機械強度的支撐基板、表面強化玻璃覆蓋所組成，太陽能電池以半導體為原料，藉由吸收太陽光的能量而提昇內部原子的外層電子位能，同時也會有部分能量以熱能的形式散逸掉，若電子獲得的能量夠高則可脫離原子形成帶負電的自由電子，而原子因失去一個電子而形成帶正電的電洞，若無電場的作用，自由電子在摩擦及碰撞之後將失去能量並與電洞復合而無法被有效的應用；一般常利用 P-N 接面的方式於半導體內部建立電場，若有自由電子或電洞在電場內產生，則受到電場的影響，自由電子向 N 型半導體移動，電洞向 P 型半導體移動，使得接面處缺少自由電子及電洞，此區域稱之為空乏區，自由電子及電洞分別向半導體兩端集中，進而產生電位差，此時若外加電路便可將電能引出使用。

表格 1 太陽能電池材料與效率之比較

太陽能電池材料	市場模組轉換效率
單晶矽	12-20 %
多晶矽	10-18 %
非晶矽	6-9 %
砷化鎵	18-30 %
碲化鎘	10-12 %

矽於自然界中含量豐富、取得容易且價格低廉，並具有較佳的光電轉換效率，故常被利用來生產太陽能電池，因成本及效率的考量，市面上較常見的矽太陽能電池有單晶矽(Single Crystalline)、多晶矽(Poly Crystalline)及非晶矽(Amorphous)等三種，單晶矽太陽能電池之矽原子有高度的周期性排列且結晶完整，故具有較高的光電轉換效率，但其晶圓型式多半為截圓型或圓弧型，因此於鋪設時無法達到最大的單位面積使用率。多晶矽太陽能電池材料特性與單晶矽太陽能電池類似，它是由多種不同排列方向的單晶所組成，結晶構造較差，光電轉換效率較單晶矽太陽能電池低，但製程上較便宜且晶圓型式可截為正方形，鋪設時可達到最大單位面積使用率並因其晶狀分佈具有藝術效果，故可用來修飾建築物外觀。非晶矽太陽能電池原子的排列方式比較紊亂，成本便宜為其優點，但具有發電效率較差且容易裂質化的缺點，應用時可直接鍍在玻璃及塑膠上面，與建築物可做最佳結合，除可做太陽光電系統發電用，室內型民生消費品也常見其應用。太陽能電池除了可以選用矽基材外，還可以

採用其他的材料，例如砷化鎵(GaAs)、碲化鎘(CdTe)等化合物半導體，以製成高效率的太陽能電池，但因這些材料成本較高，只適用在一些比較特殊的應用上，表格 1 為一些常見的太陽能電池材料與效率的比較。

一般太陽能電池是由許多 P-N 接面的半導體所組成，可將光能轉換為電能輸出，因此可以假設太陽能電池經陽光照射後如同電流源一般而供應負載使用，太陽能電池之等效電路如圖 6，圖 6 中 I_{ph} 表示太陽能電池經光照射後產生之光電流， D_j 表示一個 P-N 接面二極體， R_s 與 R_{sh} 分別代表太陽能電池內部的等效串聯電阻及等效並聯電阻， V 與 I 則為太陽能電池的輸出電壓及輸出電流。透過等效電路並結合 P-N 接面半導體的特性，可將太陽能電池等效數學模型表示如方程式(11)所示。




圖 6 太陽能電池等效電路

$$I = I_{ph} - I_{sat} [e^{q(V+IR_s)/kT} - 1] - (V + IR_s)/R_{sh} \quad (11)$$

其中 I_{sat} 為太陽能電池逆向飽和電流； q 為一個電子所含電荷量 (1.6×10^{-19} 庫侖)； A 為太陽能電池理想因數 ($A=1 \sim 5$)； k 為波茲曼常

數($1.38 \times 10^{-23} \text{ J/}^\circ\text{K}$)； T 為太陽能電池溫度(絕對溫度 $^\circ\text{K}$)。

由方程式(11)可以得知太陽能電池的一些基本特性，如太陽能電池在沒有照光的情況下，光電流為零，此時太陽能電池好比普通的二極體一樣，而在太陽能電池短路時，電壓為零，短路電流約等於光電流。

太陽光電池發電系統數值模擬部分是利用方程式(11)及表格 2，然後透過數學模擬軟體 Matlab 針對太陽能板的特性進行數值模擬，以驗證其數學模型之正確性。

表格 2 太陽能板單板電氣規格(100mW/cm^2 ， 25°C)

電氣特性	規格
額定輸出功率	104.787W
額定輸出電壓	36.014V
額定輸出電流	2.9096A
開路電路	43.446V
短路電流	3.291A
光電轉換效率	12.17%




圖 7 太陽能實測曲線




圖 8 太陽能板模擬曲線

圖 7 和圖 8 是太陽能板在測試條件為照度 $100\text{mW}/\text{cm}^2$ ，溫度 25°C 時，由太陽能板實際測量的數據所描繪之實測特性曲線及模擬特性曲線的比較圖，由圖可以發現兩者具有很高的相似度，藉此可驗證太陽能板等效數學模型的正確性，未來可利用此數學模型更進一步了解太陽能板在各種環境下其輸出電壓、電流以及功率的變化情形。




圖 9 2007 年太陽光電池發電系統模型與實際輸出功率關係

(二) 元智大學太陽光電池發電系統數值模擬

本計畫在此先針對元智大學太陽光電池發電系統其發電狀況及其效率作數值模擬，之前數模擬分析可發現太陽能板之溫度以及其照度為影響太陽光電池發電系統之最大因素，元智大學其太陽光電池發電系統之裝置容量為 5KW，另外採用 2007 及 2008 年於元智大學太陽能板設置點實際所收集之整年度照度及溫度資料，作為其輸入資訊，以觀測其與太陽光電池發電系統發電之關係並與實際太陽光電池發電系統其輸出功率做比較。




圖 10 2007 年太陽光電池發電系統模型輸出功率與溫度關係




圖 11 2007 年太陽光電池發電系統模型輸出功率與照度關係




圖 12 2008 年太陽光電池發電系統模型與實際輸出功率關係




圖 13 2008 年太陽光電池發電系統模型輸出功率與溫度關係




圖 14 2008 年太陽光電池發電系統模型輸出功率與照度關係

表格 3 元智大學太陽光電池發電系統數值模擬結果 整

數值模擬條件		裝置容量為 5kW，電源轉換效率 85%，容量因子 定義為系統實際發電量/系統全時滿載發電量			
年份	平均溫度 (°C)	平均照 度 (W/m ²)	模型輸出 電量度數 (kWh)	實際輸出 電量度數 (kWh)	容量因 子
2007	28.71	148.98	4931.64	4965	11.3%
2008	28.49	143.81	4885.42	4882	11.1%
年平均	28.6	146.4	4908.53	4923.5	11.2%

從之前所建構之太陽能模型的數值模擬中，可發現太陽能板之溫度與照度對於太陽光電池發電系統有相當大的影響，從此針對元智大學做的數值模擬中也不難發現此現象，包括從 1 月份與 2 月份資料可觀察出，當溫度資訊相去不遠時，日照強度越強，因為短路電流受照度的影響較開路電壓更為明顯，因此太陽能板將隨著日照強度的增加而進一步提供較高的輸出功率，此外，當環境溫度升高，因短路電流會些微的增加，因此導致輸出功率將因環境溫度的升高而減少。此針對元智大學做的數值模擬中也可觀察出其太陽能板等效數學模型的正確性與太陽光電池發電系統發電量與其裝置容量之關係，所建立的數學模型與系統實際發電量其平均誤差約為 1% 以內，此外根據模擬可得知太陽光電池發電系統在元智大學其容量因子約為 11.2%，在建立此模型後，對未來針對部區域設置太陽光電池發電系統可有更進一步的參考資訊。

(三) 各地區太陽光電池發電系統數值模擬

本計畫在此針對 部、中部、 部和離島地區太陽光電池發電系統之發電狀況及其效率作數值模擬， 部地區選取台 作為參考點、中部地區選取台中為參考點、 部地區選取高 為參考點以及離島地區選取 為參考點，在此是設定其太陽光電池發電系統之裝置容量為 5kW，電源轉換效率設定為 85%，另外採用 2008 年中氣象局觀測 所收集之照度及溫度資料，作為其輸入資訊，以觀測太陽光電池發電系統之發電量，其結果整理如 所示。

觀測

觀測 經 度位置為經度 119 33'19"E， 度 23 34'02"N，其觀測 設置於 10.7 公 。




圖 15 太陽光電池發電系統模型輸出電量與溫度關係




圖 16 太陽光電池發電系統模型輸出電量與照度關係

台 觀測

台 觀測 經 度位置為經度 120 30'24"E， 度 25 02'23"N，
其觀測 設置於 5.3 公 。




圖 17 台 太陽光電池發電系統模型輸出電量與溫度關係




圖 18 台 太陽光電池發電系統模型輸出電量與照度關係




圖 19 台中太陽光電池發電系統模型輸出電量與溫度關係

台中觀測

台中觀測 經 度位置為經度 120 40'33"E， 度 24 08'51"N，

其觀測 設置於 84.04 公 。

高 觀測

高 觀測 經 度位置為經度 120 18'29"E， 度 22 34'04"N，

其觀測 設置於 2.3 公 。




圖 20 台中太陽光電池發電系統模型輸出電量與照度關係




圖 21 高 太陽光電池發電系統模型輸出電量與溫度關係




圖 22 高 太陽光電池發電系統模型輸出電量與照度關係

從之前所建構之太陽能模型以及元智大學 2007 及 2008 年溫度

照度資訊的數值模擬中，可發現太陽能板之溫度與照度對於太陽光電池發電系統有相當大的影響，此針對全 灣 部、中部、 部以及離島地區所做的數值模擬中也不難發現此現象，此針對各地區做的數值模擬中主要可觀察出其太陽光電池發電系統發電量與其裝置容量之關係，在本數值模擬中，所建立的 部地區太陽光電池發電系統其容量因子(Capacity Factor)約為 10.7%、中部地區太陽光電池發電系統其容量因子約為 14.4%、 部地區太陽光電池發電系統其容量因子約為 14.3%以及離島地區太陽光電池發電系統其容量因子約為 13.9%，太陽光電池發電系統數值模擬結果 整如表格 4 所示。

表格 4 太陽光電池發電系統數值模擬結果 整

數值模擬條件	裝置容量為 5kW，電源轉換效率 85%，容量因子定義為系統實際發電量/系統全時滿載發電量			
	月平均溫度(°C)	月平均照度(W/m ²)	系統年發電量(kWh)	容量因子
部地區(台)	23.12	125.24	4685.28	10.7%
中部地區(台中)	23.39	168.23	6311.31	14.4%
部地區(高)	25.08	167.36	6245.07	14.3%
離島地區()	23.35	161.55	6074.01	13.9%

由於環境溫度及照度資訊易受到中 氣象局所設置之觀測 位置影響，例如台中以及高 兩觀測 ，因為其觀測 所設置的高度等問題，也因此導致台中地區的平均照度大於高 地區，所以其中部太陽光電池發電系統發電量也大於 部地區，這也提 之後設置

太陽能發電系統時，其位置點之重要性；本計畫在獲得各地區太陽光電池發電系統之裝置容量因子後，對未來針對各區域設置混合能源發電系統時可有更進一步的評估資訊。

(四) 建立風力發電系統模型

雖然科技的進步為人類的生活帶來許多的便利，但同時也生出許多的問題，隨著石化燃料存量減少、能源價格的、能源危機意識起、環保意識抬頭、都定的規範，除了減少現有能源使用的費外，新能源的開發更是不容緩。一般新能源對環境的衝擊不大，其所造成之空氣、水或廢物等污染行為較不著，更重要的是此種能源開發更可重複使用，具有續發展的特性，再生能源(Renewable Energy)為新能源中較受到重視的，包含太陽能、風力、生質能、地熱、能及非水力等可續利用的能源。此外，預估至西元 2020 年時，全世界風力發電將提供百分之十二的電力需求，風力發電在十世就已經在使用，最近二十年才又被重視而行。風力發電被重視的原因，主要包括(1)技術開發已臻成熟、(2)可減少污染排放、(3)政提供誘因以及(4)建廠時間短；但風力發電亦存在期投資成本高以及風力供給不穩定之缺點。

風力發電自 80 年代開始受到歐美各國重視以來，至今全球風電發電量以每年 30% 的人速度快速成長。圖 23 列出 2001-2010 年全

全球風力發電 機裝置容量以及表格 5 整未來預估再生能源佔整體發電量比例。




圖 23 2001-2010 年全球風力發電 機裝置容量

表格 5 預估未來再生能源佔發電量目標比例

國家/地區	2006 年	2020 年目標
瑞典	40.0%	49%
地利	23.0%	34%
丹麥	17.0%	30%
法國	10.0%	23%
西班牙	8.7%	20%
德國	5.8%	30%
意大利	5.2%	17%
荷蘭	2.4%	14%
英國	1.3%	15%
台灣	1.0%	8%(2025 年)

對風力發電系統而言，擷取風能之機構為風力發電機組，首先定義風機 之 端速度比 γ 如下：

$$\gamma = \frac{r \omega_m}{v} \quad (12)$$

其中 r (m)、 ω_m (rad/s) 以及 v (m/s) 分別表示風機 之半徑、發電機轉軸之轉速以及風速。此外，風力發電之功率係數為 端速度比之函數 $C_p = f_g(\gamma)$ ，不同 之風力機組具有不同功率係數與 端速度比之對應關係。

本計畫所使用風力發電系統之功率係數如圖 24 所示，當 端速度比為 $\gamma = 5.09$ 時，此時功率係數發生最大值為 $C_p = 0.42$ ，兩者之對應關係，本文以下列近似函數來表示：




圖 24 功率係數對應 端速度比

$$C_p = \begin{cases} (1.12\gamma - 2.8)\exp(-0.38\gamma), & \gamma \geq 2.5 \\ 0, & \gamma < 2.5 \end{cases} \quad (13)$$

其中 $\exp(\cdot)$ 代表指數函數。發電機所產生之機械功率 P_m (W) 正比於空氣密度 ρ (kg/m³)、轉面積 A (m²)、功率係數以及風速的立方，其機械功率可表示為

$$P_m = 0.5 \rho A C_p v^3 \quad (14)$$

本計畫在此先以元智大學為例，其風力發電系統之裝置容量為 1.4kW 以及電源轉換效率設定為 45%，另外採用 2008 年於元智大學風力機所收集之風速資料，作為其輸入資訊，以觀測其與風力發電系統發電之關係並與實際風力發電系統其輸出電量做比較，如表格 6 以及圖 25 至圖 26 所示。




圖 25 風力發電系統模型與實際輸出電量關係




圖 26 風力發電系統模型輸出電量與風速關係

從上述所建構之風力模型以及搭配元智大學所集之風力資訊所做的數值模擬中，可觀察出其風力發電系統之等效數學模型與實際輸出大致符合，其平均誤差大約在 2.6% 以內，可驗證所建構風力模型之正確性，不過受制於風速資訊有些遺、實際風力發電系統最大功率擷取效率以及風天氣等因素影響，所以其模型與實際輸出還是略有差異，此外，電源轉換效率對於最後系統輸出有很大的影響，未來實際設置風力發電系統時，應盡可能選用高能源轉換效率的產品，在確所建構風力發電系統模型之正確性後，接下來可利用此模型針對部、中部、部以及離島地區進行數值模擬以確其不同地區風力發電系統之特性。

表格 6 元智大學風力發電系統數值模擬結果 整

數值模擬條件			
裝置容量為 1.4kW，電源轉換效率 45%			
年份	平均風速 (m/s)	模型輸出電量 度數 (kWh)	實際輸出電量 度數 (kWh)
2008	2.87	208.5	213.96

(五) 各地區風力發電系統數值調查

本計畫在此針對台灣部、中部、部和離島地區已建置之風力發電系統之實際發電量以及其裝置容量做調查，以便得知各地區風力發電系統之容量因子，根據台電續產業發展雙月 - 色能源專輯[21]所提供之資料示，部地區包含台石門、大、大、新以及台口風力發電廠；中部地區包含台中電廠、台中區、工業西區、工業區、化功、化

、
、
四 風力發電廠； 部地區包含
以及台 門風力發電廠；離島地區則有 中 風力發電廠，其
結果整理如表 7 至表 10 所示。

部地區

表 7 部地區風力發電系統裝置容量與實際發電量關係

廠址名稱	總裝置容量(MW)	年發電量(百 度)	容量因子
石門風力	3.96	9.6	27.67%
大	26.5	82.6	35.58%
大 觀	30	91.2	34.7%
新	12	33.4	31.77%
台 口	12	37.2	35.39%
總和	84.46	254	34.33%

中部地區

表 8 中部地區風力發電系統裝置容量與實際發電量關係

廠址名稱	總裝置容量(MW)	年發電量(百 度)	容量因子
台中電廠	8	19.4	27.68%
台中 區	36	92.3	29.27%
工線西區	32	100.2	35.74%
工 區	30	86.5	32.91%
	48	132.7	31.56%
四	28	79	32.21%
化 功	16	45.5	32.46%
化	28	74.2	30.25%
總和	226	629.8	31.81%

部地區

表 9 部地區風力發電系統裝置容量與實際發電量關係

廠址名稱	總裝置容量(MW)	年發電量(百 度)	容量因子
風力	4.5	11.6	29.43%
台 門	14	34.5	28.13%
年平均與總和	18.5	46.1	28.45%

離島地區

表 10 離島地區風力發電系統裝置容量與實際發電量關係

廠址名稱	總裝置容量(MW)	年發電量(百 度)	容量因子
中 風力	2.4	8.6	40.91%
中 擴建	2.4	8.6	40.91%
年平均與總和	4.8	17.2	40.91%

表 11 各地區已建置風力發電系統數值調查結果 整

地區	總裝置容量(MW)	年發電量(百 度)	容量因子
部地區	84.46	254	34.33%
中部地區	226	629.8	31.81%
部地區	18.5	46.1	28.45%
離島地區	4.8	17.2	40.91%

本報告針對全 灣 部、中部、 部以及離島地區已建置之風力發電系統其裝置容量與實際發電量之關係做調查，根據所調查之資料 示， 部地區風力發電系統其容量因子(Capacity Factor)約為 34.33%、中部地區風力發電系統其容量因子約為 31.81%、 部地區風力發電系統其容量因子約為 28.45%以及離島地區風力發電系統其容量因子約為 40.91%，風力發電系統數值調查結果 整如表 11 所示；本計畫在獲得各地區風力電系統之裝置容量因子後，對未來針對各區域設置混合能源發電系統時可有更進一步的評估資訊。

(六) 燃料電池基本原理及模型建立






圖 27 燃料電池系統示意

燃料電池是一種直接將燃料之化學能轉換為電能的裝置，運作原理可解為水電解的逆反應。構成燃料電池得基本元件包括電極 (Electrode)、電解質膜 (Electrolyte Membrane) 以及集電器 (Current Collector) 等，電極是燃料氧化與氧化還原的電化學反應發生的場所，可分為陽極 (Anode) 與陰極 (Cathode) 兩部份，電解質的功能是分隔氧化與還原並同時傳導質子；集電器也可稱作雙極板 (Bipolar Plate)，它具有收集電流、導反應氣體以及分隔氧化與還原的作用。當燃料以氣由陽極進入，氣被觸分解成為質子與電

子，電力是由電子的流動而產生，另外 質子則 過電解質與從陰極來的氧氣，並且再加上回路的電子結合之後產生水和熱，燃料電池其系統示意如圖 27 所示。

燃料電池有多種分類方式，如以燃料電池之電解質來區分，可分為

1. 性燃料電池 Alkaline fuel cell, AFC
2. 碳 燃料電池(Molten carbonate fuel cell, MCFC)
3. 燃料電池(Phosphoric acid fuel cell, PAFC)
4. 質子交換膜燃料電池(Proton exchange membrane fuel cell, PEMFC)
5. 態氧化物燃料電池(Solid oxide fuel cell, SOFC)等5種形式，其各種燃料電池之特性以及燃料電池之特點整理如表12及表13所示。

表12 燃料電池種類與特性

電池種類	性燃料電池(AFC)	質子交換膜燃料電池(PEMFC)	燃料電池(PAFC)	碳燃料電池(MCFC)	態氧化物燃料電池(SOFC)
電解質	KOH	含 質子交換膜	H ₃ PO ₄	Li ₂ CO ₃ -K ₂ CO ₃	ZrO ₂
陽極	C(含 Pt)	C(含 Pt)	C(含 Pt)	Ni(含 Cr, Al)	金屬(Ni, Zr)
陰極	C(含觸煤)	C(含 Pt)、	C(含 Pt)	NiO	金屬氧化物如 LaMnO ₄
導電離子	OH ⁻	H ⁺	H ⁺	CO ₃ ²⁻	O ²⁻
工作	室溫 ~ 200°C		160°~	600°~1000°C	

溫度			220°C		
燃料	純	氣、	氣	天然氣、 氣、 氣、 煤氣	天然氣、 氣、 氣、 煤氣
氧化	純氧	空氣、氧氣	空氣、氧 氣	空氣、氧氣	空氣、氧氣
特性	1. 使用 高純度 氣做 為燃 料。 2. 低 性及 低溫較 易選擇 材料。	1. 功率密度 高，體積 小，重量 。 2. 低 性 及低溫，較 易選擇材 料。	1. 進氣中 CO 會導 致觸 中。 2. 廢熱可 予利用。	1. 不受進氣 CO 影響 2. 反應時需 循環使用 CO ₂ 。 3. 廢熱可利 用。	1. 不受進 氣 CO 影 響 2. 高溫反 應，不需依 賴觸煤的 特殊作 用。 3. 廢熱可 利用。
優點	1. 啟動 快 2. 室溫 常壓下 工作	1. 命長 2. 可用空氣 作氧化 3. 室溫工作 4. 功率大 5. 啟動速 6. 輸出功率 可隨意調 整	1. 對 CO ₂ 不感	1. 可用空氣 作氧化 2. 可用天然 氣或 作燃料	1. 可用空 氣作氧化 2. 可用天 然氣或 作燃料
缺點	1. 需以 純氧作 氧化 2. 成本	1. 對 CO 非 常感 2. 反應物需 要加	1. 對 CO 感 2. 工作溫 度高	工作溫度較 高	工作溫度 過高

	高		3.成本高 4.低於峰值功率輸出時性能下降		
系統效率	60%~70%	43%~58%	37%~47%	> 50%	50%~65%
用	太空潛水	小型發電機組 分散型發電 移動式電源 運輸工具之電源	汽電共生 分散型發電 離島地區發電 移動式電源 運輸工具之電源	汽電共生 分散型發電 取代大規模火力發電	汽電共生 分散型發電 取代中規模火力發電

表13 燃料電池特點

高效率	燃料電池依據電化學原理等溫直接將化學能轉換為電能，理論上熱電合轉換效能可達 90%以上，但是因為極化的影響，電池在工作實際轉換效率平均為 40%~60%左右，熱電合併效率為 80%。低：燃料電池結構很簡單並沒有運轉機械，所以它的運作上非常安進行。
低污染	由於燃料電池之所使用的燃料在反應前必須脫而且不經過燃，大量減對環境的汙染，也就是說以純為燃料時，一產物為水。
進料多元	針對燃料電池而言，燃料來源例如天然氣、石油、煤炭

	等氣化產物，或者是 氣、 精、 等，能源多元化 可以減少主流能源的 。
用 廣	應用的產品非常多，包括可 式電力、 電力、現場 型汽電共生電廠、分散型電廠以及集中型電廠。

本計劃所使用之燃料電池輸出電壓方程式[22]如下：

$$V_{FC} = E_{Nernst} - V_{act} - V_{ohmic} - V_{con} \quad (15)$$

其中 E_{Nernst} 代表燃料電池可逆電壓、 V_{act} 代表燃料電池克服活化能所
損失電位、 V_{ohmic} 代表燃料電池歐 極化所損失之電位以及 V_{con} 代表
度極化所造成之電位損失。方程式(15)中之 V_{act} 、 V_{ohmic} 以及 V_{con} 亦可
分別表示如下：

$$V_{act} = -[\xi_1 + \xi_2 * T + \xi_3 * T * \ln(c_{o_2}) + \xi_4 * T * \ln(i_{FC})] \quad (16)$$

$$V_{ohmic} = i_{FC} * (R_M + R_C) \quad (17)$$

$$V_{con} = -B * \ln(1 - \frac{J}{J_{max}}) \quad (18)$$

其中 ξ_1 、 ξ_2 、 ξ_3 及 ξ_4 代表電化學反應內部參數、 c_{o_2} 代表燃料電池陰
極氧氣 度(mol/cm^3)、 i_{FC} 代表燃料電池輸出電流(A)、 T 代表膜反應
溫度(K)、 R_M 代表膜等效電阻(Ω)、 R_C 代表膜等效接觸電阻(Ω)、 B
為用於計算 度極化損失之系統參數(V)、 J_{max} 代表燃料電池最大電
流密度(A/cm^2)以及 J 代表燃料電池實際電流密度(A/cm^2)。此外，膜
等效電阻 R_M 又可表示為

$$R_M = \frac{\rho_M * \ell}{A} \quad (19)$$

其中 ρ_M 代表膜之電阻率($\Omega\text{-cm}$)、 l 代表膜之厚度(μm)以及 A 代表膜之反應面積(cm^2)。因此燃料電池輸出功率可表示為

$$P_s = n * V_{FC} * i_{FC} \quad (20)$$

其中 n 代表燃料電池單電池數目、 V_{FC} 代表燃料電池輸出電壓(V)以及 i_{FC} 代表燃料電池輸出電流(A)。

基於能源與環保之觀點來說，各種綠色能源科技在 20 世紀後期得以發展，如風能、太陽能、地熱、潮汐等發電的技術都有所進步，而且最具有發展潛力之能源科技應屬氢能 Hydrogen Energy 科技，特別是燃料電池技術已趨近於商業化，極有可能成為 21 世紀最重要的綠色科技之一，而本計畫在建立燃料電池之數學模型後，未來可利用燃料電池實際測試之數據與其模型做比對，以驗證其正確性。

(七) 燃料電池發電系統驗證

本計畫系統採用 公司所生產的 PEMFC 之燃料電池，其電池規格如表 14 所示。利用之前所建立之燃料電池數學模型及燃料電池實測數據，透過數學模擬軟體 Matlab 針對燃料電池的特性進行數值模擬，以驗證其數學模型之正確性。

表 14 燃料電池規格

電池特性	規格
MEA 反應面積	11.3cm*13cm

膜材 度	0.0254mm
MEA 度	0.49mm
膜等效接觸電阻	29mΩ
電流密度	676.92mA/cm ²
額定功率	1kW




圖 28 燃料電池實測曲線與數值模擬曲線

圖 28 是由 22 單電池 而成之燃料電池在測試條件為溫度 65°C 時，由廠 提供持續運轉 61 小時的數據所描繪之實測特性曲線及之前所建立之燃料電池模型所模擬特性曲線的比較圖，由圖可以發現兩者大致符合，藉此可驗證燃料電池發電系統之等效數學模型的正確性，未來在建立混合能源系統時，此模型可有利於設置燃料電池發電系統之評估。

二、 建立混合能源裝置容量最佳化模擬機制

(一) 混合能源裝置容量最佳化模擬機制

本計畫所提出混合能源裝置容量最佳化機制主要是用於 超約罰款以及緊急備用電源部份，在此結合考慮裝置成本以及回收年限建構一 混合能源裝置容量最佳化機制。

首先根據設置廠址的歷史用電資訊找出其最佳契約容量，並定義其政策性超約需量(P_{2p} 和 P_{3p} 代表超過契約容量 10%以內和 10%以上之用電量)，接著根據設置廠址實際可適合架設混合能源系統之最大面積，包括必須挑選致高點且無 物可裝置太陽能板之最大面積 A_s ，以及評估足以容納風力機且風場 好之最大面積 A_w ，接著利用所找出可裝置混合能源之最大面積 A_s 與 A_w 找出太陽能光電池發電系統與風力發電系統可裝置最大容量，而每一廠址都有其必須提供之緊急備用電力，由於燃料電池本身發電不受到氣候等外部因素影響，因此其將所需之緊急備用電力設為燃料電池之裝置容量 f_{cap} 。接著收集當地風速、照度以及溫度資訊，透過所建立之太陽能光電池發電系統與風力發電系統動態數學模型，找出當地太陽能光電池發電系統以及風力發電系統之容量因子(s_{fac} 及 w_{fac})，以確保供應足夠且穩定品質之電力予負載端，之後設定模擬情境及預期回收年限 Year，結合所找出之容量因子與廠址實際可裝置混合能源系統之最大面積去設計所有裝置容量之可能組合，其負載端與容量因子關係式以及 費成本式子[23]如下：

$$Power = s_{fac} * s_{cap} + w_{fac} * w_{cap} + f_{fac} * f_{cap} \quad (21)$$

$$Cost = \sum_{i=w,s,f} (I_i - S_{P_i} + OM_{P_i}) \quad (22)$$

其中 w 、 s 和 f 分別是代表太陽能光電池發電系統、風力發電系統以及燃料電池發電系統，下標「 $_{fac}$ 」及「 $_{cap}$ 」分別代表容量因子及裝置容量； I_i 、 S_{P_i} 以及 OM_{P_i} 分別代表設置成本、價值以及維 成本。

成本計算主要分為以下三個部分：

1. 裝置成本

$$I_w = w_{cost} * w_{cap} \quad (23)$$

$$I_s = s_{cost} * s_{cap} \quad (24)$$

$$I_f = f_{cost} * f_{cap} \quad (25)$$

其中 w_{cost} 、 s_{cost} 和 f_{cost} 分別代表風力發電系統、太陽能光電池發電系統以及燃料電池發電系統每 之裝置費用，而 w_{cap} 、 s_{cap} 和 f_{cap} 分別代表風力發電系統、太陽能光電池發電系統以及燃料電池發電系統之裝置容量。

2. 價值

$$S_{P_w} = 0.1 * w_{cost} * w_{cap} * \left(\frac{1+\beta}{1+\gamma} \right)^{N_p} \quad (26)$$

$$S_{P_s} = 0.1 * s_{cost} * s_{cap} * \left(\frac{1+\beta}{1+\gamma} \right)^{N_p} \quad (27)$$

$$S_{P_f} = 0.1 * f_{cost} * f_{cap} * \left(\frac{1+\beta}{1+\gamma} \right)^{N_p} \quad (28)$$

其中 S_{P_w} 、 S_{P_s} 以及 S_{P_f} 代表風力發電系統、太陽能光電池發電系統以

及燃料電池發電系統之價值，回收價值約為設置成本 1/10， β 是代表通率、 γ 是行之利率， N_p 是系統使用年份。

3. 維費用

$$OM_{P_w} = 0.05 * w_{cost} * w_{cap} * \sum_{j=1}^{N_p} \left(\frac{1+\nu}{1+\gamma} \right)^j \quad (29)$$

$$OM_{P_s} = 0.01 * s_{cost} * s_{cap} * \sum_{j=1}^{N_p} \left(\frac{1+\nu}{1+\gamma} \right)^j \quad (30)$$

其中 OM_{P_w} 以及 OM_{P_s} 代表風力發電系統以及太陽能光電池發電系統之維成本，每年之維費用約為設置成本 5% 以及 1%，燃料電池則是可使用一定時間(例如 4000 小時)，年限一到即直接換新，沒有維費用之問題，而 ν 是代表維費用成長率、 γ 是行之利率， N_p 則是系統使用年份。

整合混合能源供電系統後，將電力供應於廠址使用時，其成本回收主要考慮以下四部分：

1. 超約罰款

$$M_{2p} = (sm_{cap_cost} * sm_{mon} + wt_{cap_cost} * wt_{mon}) * 2 * P_{2p} \quad (31)$$

$$M_{3p} = (sm_{cap_cost} * sm_{mon} + wt_{cap_cost} * wt_{mon}) * 3 * P_{3p} \quad (32)$$

$$M_p = M_{2p} + M_{3p} \quad (33)$$

其中 M_{2p} 和 M_{3p} 代表超約 2 倍和 3 倍罰款， P_{2p} 和 P_{3p} 代表超過契約容量 10% 以內和 10% 以上之用電量， sm_{mon} 和 wt_{mon} 分別是代表電力公司

所公告之 月與非 月數目， sm_{cap_cost} 和 wt_{cap_cost} 代表 月與非 月契約容量每 之費用 台灣電力公司目前所公告一年 月有 4 個月，其 月契約容量每 為新台幣 236.2 元，非 月契約容量每 為新台幣 173.2 元。

2. 節 基本電費

$$M_b = (sm_{cap_cost} * sm_{mon} + wt_{cap_cost} * wt_{mon}) * (P_w + P_s) \quad (34)$$

其中 P_w 和 P_s 分別代表風力發電系統以及太陽能光電池發電之實際功率(設置功率乘上容量因子)， sm_{mon} 和 wt_{mon} 分別是代表電力公司所公告之 月與非 月數目， sm_{cap_cost} 和 wt_{cap_cost} 代表 月與非 月契約容量每 之費用，由於燃料電池成本較高以及 命較短，因此主要應用於緊急用電，在此計算基本電費時不將燃料電池納入考慮。

3. 節 流動電費

$$M_f = (P_w + P_s) * h * d * eg_{cost} \quad (35)$$

其中 P_w 和 P_s 分別代表風力發電系統以及太陽能光電池發電之實際功率(設置功率乘上容量因子)， h 及 d 分別代表一天 24 小時以及一年 365 天， eg_{cost} 代表電力公司一度電平均價格(台灣電力公司目前所公告約為新台幣 3 元)，在此一樣考慮到燃料電池成本較高以及 命較短，因此主要應用於緊急用電，在此計算流動電費時也不將燃料電池納入考慮。

4. CO_2 減量費用

$$M_{co_2} = (P_w + P_s) * wg_{co_2} * cost_{co_2} * h * d \quad (36)$$

其中 P_w 和 P_s 分別代表風力發電系統以及太陽能光電池發電之實際功率(設置功率乘上容量因子)， h 及 d 分別代表一天 24 小時以及一年 365 天， $cost_{co_2}$ 代表電力公司所公告減少每公 CO_2 之減量費用 台灣電力公司目前預估減少每公 CO_2 減 費用為 650 元，代表平均一度電產生所造成 CO_2 的量 台灣電力公司公告平均一度電產生 0.612 公 CO_2 ，在此一樣考慮到燃料電池成本較高以及 命較短，因此計算 CO_2 減量費用時也不將燃料電池納入考慮。

根據上述所考慮之條件，可得每年回收之成本如下：

$$M_r = M_p + M_b + M_f + M_{co_2} \quad (37)$$

考慮混合能源系統之使用 命時(一般太陽能板以及風力機使用 命為 20 年)，若設置成本($Cost$) 掉回收成本(M_r)無法在使用 命年限內成為負值，其設置成本即無法回收。

在此，將同一 混合能源系統改採用電力公司收購再生能源之條件，觀察其成本回收概況如下：

$$R_s = P_s * s_b * h * d \quad (38)$$

$$R_w = P_w * w_b * h * d \quad (39)$$

其中 P_w 和 P_s 分別代表風力發電系統以及太陽能光電池發電之實際功率(設置功率乘上容量因子)， R_s 以及 R_w 分別代表太陽能光電池發電系統以及風力發電系統每年賣電給電力公司所得金額， s_b 與 w_b 是電

力公司公告收購太陽能光電池發電系統以及風力發電系統每度電之費用(台灣電力公司目前 擬太陽能光電池發電系統與風力發電系統每度電收購費用約為新台幣 8.82 元以及 2.61 元)。由於燃料電池目前各地政 尚未有提出收購政策，在此就不納入討論範圍，所以可得知當裝置成本($Cost$) 掉太陽能光電池發電系統以及風力發電系統賣電給電力公司之金額(R_s 及 R_w)為負時，代表其裝置成本已回收，當系統可在預期回收年限回收時，將記錄目前最短回收年限 N_{min} ，在完成所有混合能源系統所有可能之組合後，其最短回收年限 N_{min} 之混合能源發電系統裝置比例即為此廠址之混合能源裝置黃金比例。

根據之前所建立以及調查之模型與數據，結合上述所考慮之成本回收年限，混合能源裝置容量最佳化模擬機制流程圖 29 所示。

在此以元智大學作為實際測試廠址，根據元智大學電力監控系統之資料，元智大學 98 年用電超過契約容量 10% 以上為 176kW，此外，針對學 重要資料庫皆設置於資服處，因此必須不受電力公司電力系統故障保持運作，在此將混合型能源發電系統運用於 超約三倍罰款以及緊急備用電源部份。

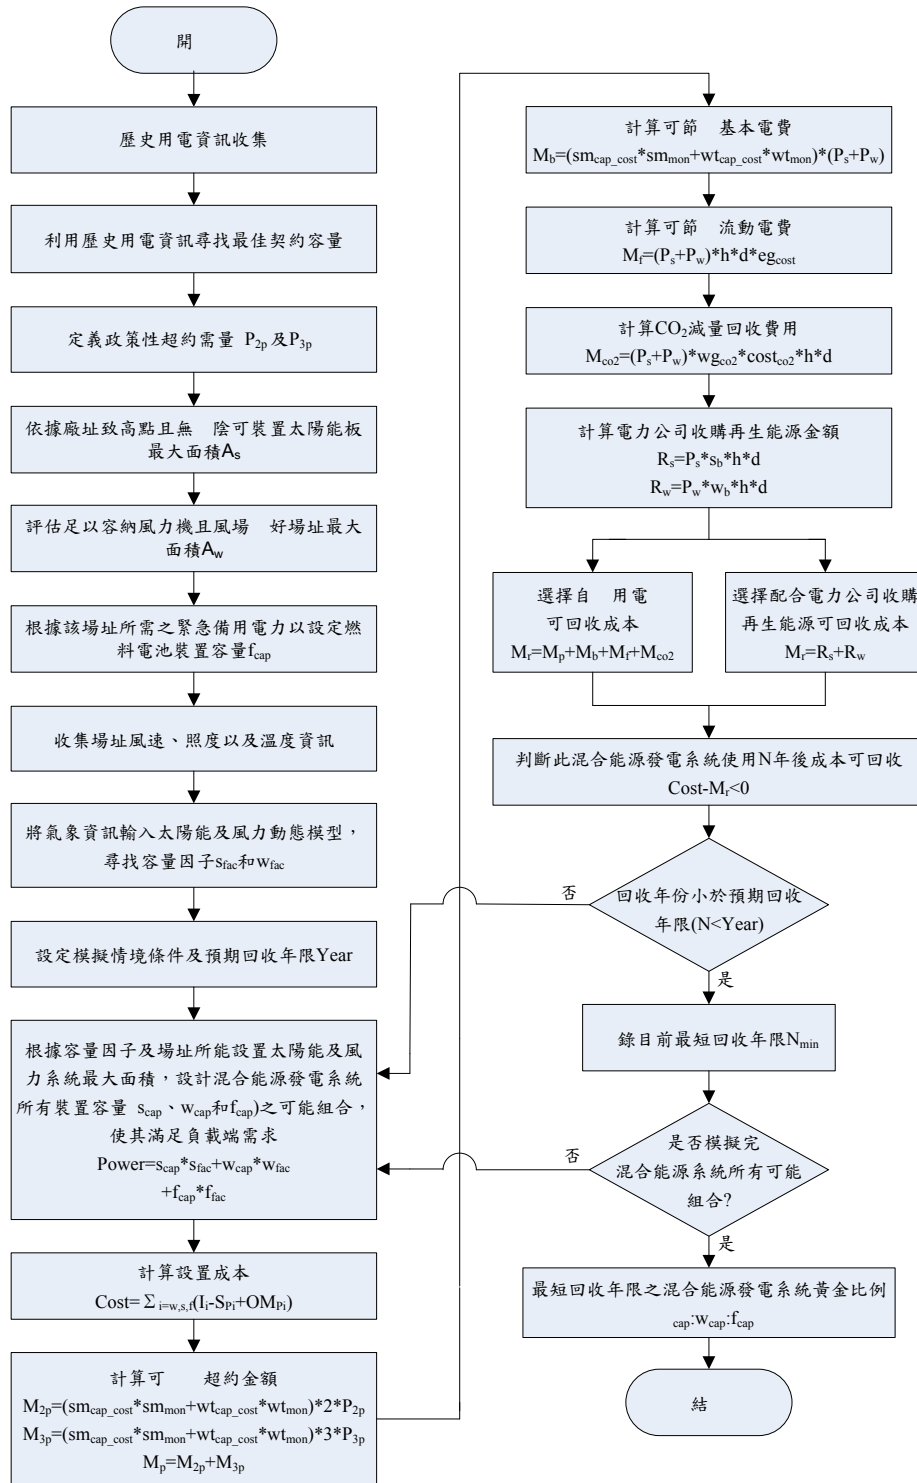


圖 29 混合能源裝置容量最佳化模擬機制

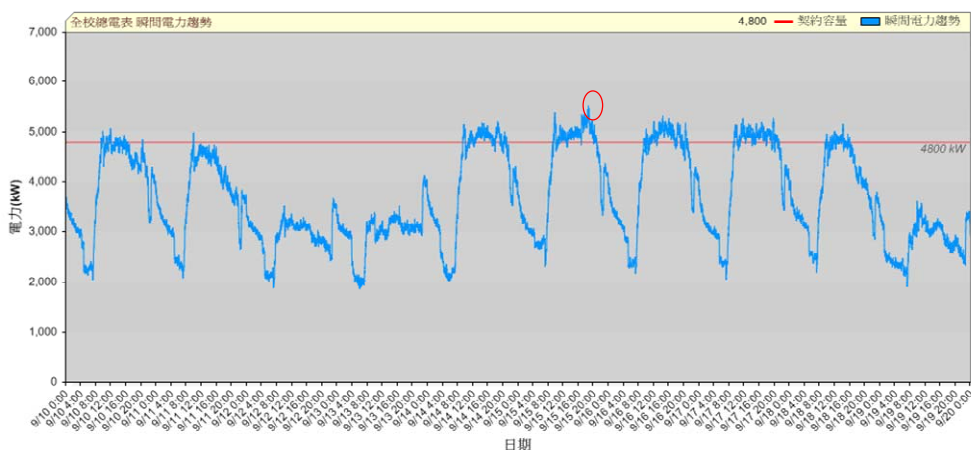


圖 30 元智大學 98/9/10 至 98/9/20 全 用電需量與契約容量關係




圖 31 元智大學 98/9/15 全 用電需量與契約容量關係

(二) 數值模擬

在此利用 98 年元智大學電力管理與控制系統所得 用電分析，可得知其發生最大超約時間發生在 9 月 15 號，其超約容量為 656kW，圖 30 為元智大學 98 年 9 月 10 號至 9 月 20 號之全 用電需量與契約容量之關係。圖 31 為元智大學 98 年 9 月 15 號用電需量與契約容量之關係，可 得知其最大用電需量為 5456kW，契約容量為 4800kW，其超約容量為 656kW。根據元智大學電力監控系統

所得資服處之用電情形，可得知其用電最尖峰發生在 98 年 7 月 6 號，其用電尖峰值約為 72kW，圖 32 為元智大學 98 年 7 月 1 號至 7 月 10 號資服處用電曲線。圖 33 為元智大學 98 年 7 月 6 號資服處當日用電曲線，可得知其最大用電需量為 72kW。




圖 32 元智大學 98/7/1 至 98/7/10 資服處用電曲線




圖 33 元智大學 98/7/6 資服處用電曲線

燃料電池在混合能源系統中，因其發電價格較為昂貴，主要係演提供緊急用電之角色，因此預設燃料電池必須可提供資服處之用電量，根據 98 年元智電力監控系統所提供資料，可得知其必須能

提供約 72kW 之電力，故設置其燃料電池之裝置容量為 72kW， 掉燃料電池之設置容量 72kW， 太陽能及風力必須提供 104KW(176-72=104kW)以抑制超約三倍罰款。

考慮到元智大學實際可裝設太陽能光電池以及風力發電系統之面積，依據每 3 可安裝 1kW 太陽能板，元智大學 共可裝設約 210kW 太陽能光電池系統，風力發電系統約為 250kW，而燃料電池依然運用於緊急備用電源，因此裝置容量同樣為 72kW，根據先前模擬以及調查資料可得知 部地區太陽能光電池發電系統與風力發電系統之容量因子分別為 10.7%以及 34.33%，接著利用所建立之混合能源裝置容量最佳化模擬機制找出元智大學裝設混合能源發電系統之黃金比例，元智大學場址分析所用到之參數如表 15 所示。

表 15 元智大學場址分析參數

名稱	數值
負載端需求功率	176
太陽能發電系統每 裝置費用	新台幣 100,000 元
風力發電系統每 裝置費用	新台幣 50,000 元
燃料電池發電系統每 裝置費用	新台幣 280,000 元
太陽能板使用年限	20 年
風力機使用年限	20 年
燃料電池使用 命	4,000 小時
通 率	1.3%
行利率	1.341%
電力公司收購太陽能光電池發電系統每度電價格	新台幣 8.82 元
電力公司收購風力發電系統每度電價格	新台幣 2.61 元
電力公司每公 CO ₂ 減量回收價格	新台幣 650 元
每度電 CO ₂ 產生量	0.612 公

表 16 混合能源系統於元智大學場址設置回收年限

混合能源系統種類與容量大小	自 用 電 回 收 年 限	配合電力公 司收購回收 年 限
太陽能+風力+燃料電池 ($169.86*0.107+250*0.3433+72*1=176$)	14	17

經由混合能源供電系統動態模型整合及裝置容量最佳化模擬機制，可將混合能源系統於元智大學場址設置回收年限整理如表 16 所示，資料 示自 用 電回收年限約為 14 年，若配合電力公司收購回收年限則 長為 17 年，其主因在於元智大學風力發電效益最高，但風力發電收購電價偏低所致，上述之情境分析並未考慮到未來技術成熟時成本下降以及未來政 政策 助，所以未來組裝此混合能源系統時，實際回收年限將會小於表 16 所呈現之結果。

(三) 靈 度分析

本計畫提出一混合能源發電系統裝置容量最佳化機制，可針對不同設置廠址之實際情設計出最具有經濟效益之混合能源發電系統裝置容量配比，目前本計畫是運用所建立之再生能源動態數學模型、台電資料以及政 所公佈之法規等資料定義混合能源發電系統裝置容量最佳化機制中之因子，包括再生能源之容量因子、再生能源裝置費用以及再生能源收購費用等，而在評估每一廠址其混合能源最佳裝置容量時，可能會因為一些未知因素有些許誤差，加上未來各種費用以及相關法規都會有所變動，所以在此針對某些自身變

動較大以及對於混合能源發電系統裝置容量最佳化機制有較大影響之因子做分析，以利未來使用者更 評估裝置混合能源發電之經濟效益。

例來說，目前混合能源發電系統裝置容量最佳化機制中之風力發電系統之容量因子，其是利用台電目前全台灣已裝設之大型風力發電廠之資料做分析所得，由於未來設置廠址其可能有別於台電所裝設之大型風力發電機，而是裝設中小型發力發電機，因此其風力發電系統之容量因子可能會有所不同，這對於最後所評估出之經濟效益可能也會有些許落差，在此針對特定因子做靈 度分析，目的可以 使用者使用目前所建立合能源發電系統裝置容量最佳化機制時，可 針對某些可能有變化之因子(如先前所 例之風力發電系統之容量因子)對於最後評估結果的影響程度， 使用者可以較保險評估其經濟效益。

在此針對風力發電系統之容量因子、燃料電池每 之裝置費用、電力公司太陽能收購價格以及風力收購價格 4 個對於結果有較大影響之因子做分析。

1.風力發電系統容量因子:

如上述所提，目前風力發電系統之容量因子是根據台電目前已裝設之大型風力發電廠之資訊所得，而考慮到風機大小之差異問題，因此在此是將原先調查 部風力發電容量因子 34.33%做±30%之

變化，亦即風力發電系統容量因子範圍為 24%~44.6%，觀察當風力發電系統之容量因子有所不同時，其對於最後系統回收年限之影響，以利使用者評估整體經濟效益。

2. 燃料電池每 之裝置費用

隨著環保意識提高，目前世界各地都積極推廣再生能源發電系統，因此各種再生能源之技術也將日臻成熟，未來各種再生能源之設置成本也將逐年降低，除目前發展技術較為成熟的太陽能光電池以及風力發電系統，燃料電池未來設置成本勢必會有所降低，因此在此考慮當燃料電池設置成本降低時對於系統回收年限之影響，目前燃料電池每 設置費用設定為新台幣 280,000 元，在此假設未來設置成本會逐步降低 50%(新台幣 140,000 元)時，針對其變化對於整體回收效益之影響。

3. 電力公司風力發電 購價格

目前台灣有針對風力發電系統之發電做 購，目前根據裝置容量大小每度電 購價格範圍為新台幣 如表 17 所示，本計畫目前是以 購價格新台幣 2.61 元為依據，再生能源 購價格每年都會隨著政策而改變，因此假設來技術成熟且推廣順利，那其 購價格也會因此降低，因此假設其未來 購最低價格可能降低 20%，若來推廣不順利，那其 購價格勢必會提高，由於目前風力發電成本較低， 購價格也較低，因此假設 購價格至多提高 20%，根據模擬結果觀

其購價格變動(新台幣 2.088~3.132 元)對系統回收年限之影響，模擬結果如圖 34 所示。圖 34 的 X 軸代表的是每個因子的變化百分比，Y 軸代表回收年限，利用其回收年限之範圍除上每個因子單位變化百分比，即可求出其平均回收年限變化率，將所求得變動量整理如表 18 所示。




圖 34 各種因子變化百分比與回收年限變化率關係

4. 電力公司太陽能 購價格

由於各地政 都積極推廣再生能源之發展，因此再生能源電能購費率及其計算公式法規也 生而出，目前台灣有針對太陽能光電池發電系統之發電做 購，目前根據裝置容量大小每度電 購價格範圍如表17所示，本計畫目前是以 購價格新台幣 8.82元為依據，

而再生能源 購價格每年都會隨著政策而改變，假設未來技術成熟且推廣順利，那其 購價格也會因此降低，在此假設未來 購價降低40%(新台幣 5.292 ~ 8.82元)時，對於系統回收年限之影響。

表 17 太陽光電及風力 購費率

再生能源類別	分類	級距 (kW)	100 年度費率(元/度)	99 年度公告費率(元/度)	變化率 (%)
太陽光電	型	1 ~ <10	10.3185	11.1883 * (相當於無設備助 14.6030)	-29.34
		10 ~ <100	9.1799	12.9722	-29.23
		100 ~ <500	8.8241		-31.98
		500	7.9701	-28.32	
	地面型	無區分	7.3297	11.1190	-34.08
	風力	域	1 ~ <10	7.3562	7.2714
10**			2.6138	2.3834	9.67
離		無區分	5.5626	4.1982	32.5

表 18 平均回收年限變化率變動

因子變化種類	回收年限變化率變動量
風力發電系統容量因子	0.1333
電力公司收購太陽能發電價格	0.125
電力公司收購風力發電價格	0.125
燃料電池裝置費用	0.06

根據表 18 模擬結果可得知風力發電系統之容量因子之變化對於最後系統回收年限之影響最大，其為購太陽能光電池發電系統之價格以及購風力發電系統之價格，而影響最小之因子為燃料電池裝置費用之變動，根據以上結果，有利於未來使用者評估裝置風險以及經濟效益，此外，也可針對影響較大之因子做更為細部之調查與評估，以達到更精確之預估效果。

三、 負載需量估測

在決定智慧型微型電網系統內部各種能源之配置比例之後，接下來該如何使決定智慧型微型電網所供應特定負載之用電需量，才能夠使其能夠同時達到最佳經濟效益與用電效率成為切需要解決的問題。首先建立模糊神經網路(Fuzzy Neural Network)以及粒子群優化演算法(Particle Swarm Optimization, PSO)之架構，接著分別建立短期、中期以及長期負載預測之估測模型，最後透過元智大學電力管

理以及控制系統之資料做數值模擬，驗證所提出智慧型估測架構之估測效能。




圖35 模糊類神經網路架構

(一) 模糊類神經網路模型

本計畫提出之模糊類神經網路(Fuzzy Neural Network)是將模糊理論 入類神經網路中，發展成為模糊類神經網路，其中原本類神經網路之訊號傳遞過程以模糊推理機制來完成，使得操作規則容易被人們所接受，且由於類神經模糊網路的鍵結值與歸屬函數是可調整的，故可使得實際系統的輸出與參考模式輸出間的誤差在 代過程中以最大值的方式減少。由於模糊類神經網路結合處理不確定性訊息能力之模糊推理機制與線上學習能力之類神經網路的優點，故經常將其應用在處理控制系統具有非線性和不確定性的問題，也可

同時克服解決上述所提到模糊理論以及類神經網路之缺點。

一般四層式模糊類神經模糊網路，如圖35所示[24], [25]，此網路由輸入層(Input Layer)、歸屬函數層(Membership Layer)、規則層(Rule Layer)及輸出層(Output Layer)所組成，其內部每層網路之信號傳遞過程與基本函式簡介如下：

第一層：輸入層

對於本層中第*i*個神經元其淨輸入與淨輸出表示如下：

$$net_i^1 = x_i^1, \quad y_i^1 = f_i^1(net_i^1) = net_i^1 \quad (40)$$

其中 x_i^1 表示第一層第*i*個神經元的輸入訊號。

第二層：歸屬函數層

第二層每個神經元代表對應之歸屬函數特性，歸屬函數的型式在此採用高斯函數。對於第二層第*j*個神經元而言

$$net_j^2 = -\frac{(x_i^2 - m_{ij})^2}{(\sigma_{ij})^2}, \quad y_j^2 = f_j^2(net_j^2) = \exp(net_j^2) \quad (41)$$

其中 m_{ij} 與 σ_{ij} 分別代表第二層第*i*個語言變數輸入值 x_i^2 對應第*j*個神經元內所屬高斯函數的平均值(Mean)與標準偏差(Standard Deviation)。

第三層：規則層

第三層神經元以符號 Π 表示所有輸入此神經元的訊號作相互乘積之計算。

對於第三層第*k*個神經元而言

$$net_k^3 = \prod_j w_{jk}^3 x_j^3, \quad y_k^3 = f_k^3(net_k^3) = net_k^3 \quad (42)$$

其中 x_j^3 代表輸入到第三層神經元的第 j 個輸入值， w_{jk}^3 代表歸屬函數層與規則層之間的鍵結值。

第四層：輸出層

第四層的神經元標示為 Σ ，表示將所有輸入此神經元訊號作加總計算，可表示如下：

$$net_o^4 = \sum_k w_{ko}^4 x_k^4, \quad y_o^4 = f_o^4(net_o^4) = net_o^4 \quad (43)$$

其中 w_{ko}^4 表示與第 k 條規則相關的輸出強度， x_k^4 代表輸入第四層神經元的第 k 個輸入值， y_o^4 是模糊類神經網路的輸出值。

(二) 模糊類神經網路線上學習演算法推導

模糊類神經網路在此的線上學習演算法是利用倒傳遞演算法去做調整，其主要是利用 度遞減法盡可能快速改變連結權重值、模糊規則中心點以及 度，以達到減少誤差之目標，首先定義其能量函數

$$E = (x_f - x_l)^2 / 2 = e^2 / 2 \quad (44)$$

其中 x_f 與 x_l 分別代表估測負載以及實際負載， e 代表估測負載與實際負載之誤差，因此學習演算法可如下所描述：

第四層：

其誤差項可表示為:

$$\delta_o^4 = -\frac{\partial E}{\partial y_o^4} = \left[-\frac{\partial E}{\partial e} \frac{\partial e}{\partial y_o^4} \right] = \left[-\frac{\partial E}{\partial e} \frac{\partial e}{\partial x_l} \frac{\partial x_l}{\partial y_o^4} \right] \quad (45)$$

根據上式，其權重值更新可表示為:

$$\Delta w_{ko}^4 = -\eta_w \frac{\partial E}{\partial w_{ko}^4} = \left[-\eta_w \frac{\partial E}{\partial y_o^4} \right] \left(\frac{\partial y_o^4}{\partial net_o^4} \frac{\partial net_o^4}{\partial w_{ko}^4} \right) = \eta_w \delta_o^4 x_k^4 \quad (46)$$

最後輸出層之權重更新值可表示如下式:

$$w_{ko}^4(N+1) = w_{ko}^4(N) + \Delta w_{ko}^4 \quad (47)$$

其中 η_w 表示其權重值學習率參數以及 N 表示訓練代數。

第三層:

此層誤差項可計算為:

$$\delta_k^3 = -\frac{\partial E}{\partial net_k^3} = \left[-\frac{\partial E}{\partial y_o^4} \right] \left(\frac{\partial y_o^4}{\partial net_o^4} \frac{\partial net_o^4}{\partial y_k^3} \frac{\partial y_k^3}{\partial net_k^3} \right) = \delta_o^4 w_{ko}^4 \quad (48)$$

第二層:

此層誤差項可表示為:

$$\begin{aligned} \delta_j^2 &= -\frac{\partial E}{\partial net_j^2} = \left[-\frac{\partial E}{\partial y_o^4} \frac{\partial y_o^4}{\partial net_o^4} \frac{\partial net_o^4}{\partial y_k^3} \frac{\partial y_k^3}{\partial net_k^3} \right] \left[\frac{\partial net_k^3}{\partial y_j^2} \frac{\partial y_j^2}{\partial net_j^2} \right] \\ &= \sum_k \delta_k^3 y_k^3 \end{aligned} \quad (49)$$

其中 m_{ij} 與 σ_{ij} 可分別表示為:

$$\Delta m_{ij} = -\eta_m \frac{\partial E}{\partial m_{ij}} = \left[-\eta_m \frac{\partial E}{\partial y_j^2} \frac{\partial y_j^2}{\partial net_j^2} \frac{\partial net_j^2}{\partial m_{ij}} \right] = \eta_m \delta_j^2 \frac{2(x_i^2 - m_{ij})}{(\sigma_{ij})^2} \quad (50)$$

$$\Delta\sigma_{ij} = -\eta_{\sigma} \frac{\partial E}{\partial \sigma_{ij}} = \left[-\eta_{\sigma} \frac{\partial E}{\partial y_j^2} \frac{\partial y_j^2}{\partial net_j^2} \frac{\partial net_j^2}{\partial \sigma_{ij}} \right] = \eta_{\sigma} \delta_j^2 \frac{2(x_i^2 - m_{ij})^2}{(\sigma_{ij})^3} \quad (51)$$

其中 η_m 和 η_{σ} 分別為高斯函數的中心點與 度之學習率參數，中心點及 度分別利用下式作更新：

$$m_{ij}(N+1) = m_{ij}(N) + \Delta m_{ij} \quad (52)$$

$$\sigma_{ij}(N+1) = \sigma_{ij}(N) + \Delta \sigma_{ij} \quad (53)$$

有關學習率參數的選取對於模糊類神經網路性能有很大的影響，因此為了訓練模糊類神經網路的效率，在此將提出利用輸出誤差調整三個學習率參數的變化，並利用離散式 普 函數證明其收斂，在此所證明的收斂分析式確保其輸出誤差可收斂，將得到一可適用於特定類型之網路參數之學習率參數[24], [25]。

理論 1: 假設 η_w 為模糊類神經網路權重值之學習率參數，並將 P_{wmax} 定義為 $P_{wmax} \equiv \max_N \|P_w(N)\|$ ，且 $P_w(N) = \partial y_o^4 / \partial w_{ko}^4$ 以及 $\|\cdot\|$ 代表歐幾範數。在此將證明當 $\eta_w = \lambda / (P_{wmax}^2) = \lambda / R_u$ 且 λ 為一正的常數，將可證明其可確保收斂， R_u 為模糊類神經網路之規則數。

證明：

$$P_w(N) = \frac{\partial y_o^4}{\partial w_{ko}^4} = x_k^4 \quad (54)$$

因此

$$\|P_w(N)\| < \sqrt{R_u} \quad (55)$$

離散式 普 函數定義為

$$V(N) = e^2(N) / 2 \quad (56)$$

根據上式可得到 普 函數變化可表示為

$$\Delta V(N) = V(N+1) - V(N) = [e^2(N+1) - e^2(N)] / 2 \quad (57)$$

誤差可表示為

$$e(N+1) = e(N) + \Delta e(N) = e(N) + \left[\frac{\partial e(N)}{\partial w_{ko}^4} \right]^T \Delta w_{ko}^4 \quad (58)$$

其 Δw_{ko}^4 表示為網路輸出層之權重變化，透過利用(45)、(46)和(58)可得知

$$\frac{\partial e(N)}{\partial w_{ko}^4} = \frac{\partial e(N)}{\partial y_o^4} \frac{\partial y_o^4}{\partial w_{ko}^4} = -\frac{\delta_o^4}{e(N)} P_w(N) \quad (59)$$

$$e(N+1) = e(N) - \left[\frac{\delta_o^4}{e(N)} P_w(N) \right]^T \eta_w \delta_o^4 P_w(N) \quad (60)$$

因此

$$\begin{aligned} \|e(N+1)\| &= \left\| e(N) \left[1 - \eta_w \left(\frac{\delta_o^4}{e(N)} \right)^2 P_w^T(N) P_w(N) \right] \right\| \\ &\leq \|e(N)\| \left\| 1 - \eta_w \left(\frac{\delta_o^4}{e(N)} \right)^2 P_w^T(N) P_w(N) \right\| \end{aligned} \quad (61)$$

假 設 $\eta_w = \lambda / (P_{wmax}^2) = \lambda / R_u$ ， 則 (61) 中 的

$\left\|1 - \eta_w \left(\delta_o^4 / e(N)\right)^2 P_w^T(N) P_w(N)\right\|$ 將小於1. 因此 普 函數的穩定度

$V > 0$ 以及 $\Delta V < 0$ 將可得到證明， 估測負載與實際負載的輸出誤差在時間趨近於無 大的時候將可收斂到0，這個結果完全符合所提出的第一個理論。

輔助定理1: 定義 $p(z) = z \exp(-z^2)$ ，則 $|p(z)| < 1, \forall z \in \mathfrak{R}$

輔助定理2: 定義 $q(z) = z^2 \exp(-z^2)$ ，則 $|q(z)| < 1, \forall z \in \mathfrak{R}$

理論2: 定義 η_m 與 η_σ 為模糊類神經網路中高斯函數的中心點與 度之學習率參數，將 P_{mmax} 定義為 $P_{mmax} \equiv \max_N \|P_m(N)\|$ ，且

$P_m(N) = \partial y_o^4 / \partial m_{ij}$ 以及 $\|\cdot\|$ 代表歐幾 範數。在此將證明當 η_m 與 η_σ

選擇為 $\eta_m = \eta_\sigma = \eta_w \left[w_{ko max}^4 \left| (2 / \sigma_{ij min}) \right|^2 \right]$ ，其中 $\eta_w = \lambda / R_u$ 、 λ 是一為正的

常數、 $w_{ko max}^4$ 定義為 $w_{ko max}^4 = \max_N [w_{ko}^4(N)]$ 、 $\sigma_{ij min}$ 定義為

$\sigma_{ij min} = \max_N [\sigma_{ij}(N)]$ 以及 $|\cdot|$ 為絕對值。

證明:

根據輔助定理1，可得知 $\left| \left[(x_i^2 - m_{ij}) / \sigma_{ij} \right] \exp \left\{ - \left[(x_i^2 - m_{ij}) / \sigma_{ij} \right]^2 \right\} \right| < 1$ ，因

為

$$\begin{aligned} P_m(N) &= \frac{\partial y_o^4(N)}{\partial m_{ij}} = w_{ko}^4 \left\{ \frac{\partial y_k^3}{\partial net_k^3} \frac{\partial net_k^3}{\partial y_j^2} \frac{\partial y_j^2}{\partial m_{ij}} \right\} = w_{ko}^4 \frac{\partial y_j^2}{\partial m_{ij}} \\ &< w_{ko}^4 \left\{ \max \left(\frac{2}{\sigma_{ij}} \right) \right\} = w_{ko}^4 \left(\frac{2}{\sigma_{ij min}} \right) \end{aligned} \quad (62)$$

因此

$$\|P_m(N)\| < \sqrt{R_u} |w_{ko\max}^4| (2/\sigma_{ij\min}) \quad (63)$$

誤差關係可表示成

$$e(N+1) = e(N) + \Delta e(N) = e(N) + \left[\frac{\partial e(N)}{\partial m_{ij}} \right]^T \Delta m_{ij} \quad (64)$$

其中 Δm_{ij} 代表歸屬層的高斯函數中心點變化，透過利用(35), (40)以及(54), 可得到

$$\frac{\partial e(N)}{\partial m_{ij}} = \frac{\partial e(N)}{\partial y_o^4} \frac{\partial y_o^4}{\partial m_{ij}} = -\frac{\delta_o^4}{e(N)} P_m(N) \quad (65)$$

$$e(N+1) = e(N) - \left[\frac{\delta_o^4}{e(N)} P_m(N) \right]^T \eta_m \delta_o^4 P_m(N) \quad (66)$$

因此

$$\begin{aligned} \|e(N+1)\| &= \left\| e(N) \left[1 - \eta_m \left(\frac{\delta_o^4}{e(N)} \right)^2 P_m^T(N) P_m(N) \right] \right\| \\ &\leq \|e(N)\| \left\| 1 - \eta_m \left(\frac{\delta_o^4}{e(N)} \right)^2 P_m^T(N) P_m(N) \right\| \end{aligned} \quad (67)$$

假設 η_m 選擇為 $\eta_m = \lambda / (P_{m\max}^2) = \eta_w [w_{ko\max}^4 | (2/\sigma_{ij\min})]^{-2}$, 則(67)中的

$\left\| 1 - \eta_m \left(\frac{\delta_o^4}{e(N)} \right)^2 P_m^T(N) P_m(N) \right\|$ 將小於1. 因此 普 函數可透過

(56)與(57)得到 $V > 0$ 以及 $\Delta V < 0$ 之結果可證明穩定度，估測負載與

實際負載的輸出誤差在時間趨近於無 大的時候將可收斂到0。

根據輔助定理2，可得知 $\left|[(x_i^2 - m_{ij})/\sigma_{ij}]^2 \exp\{-[(x_i^2 - m_{ij})/\sigma_{ij}]^2\}\right| < 1$ ，因

為

$$\begin{aligned}
 P_\sigma(N) &= \frac{\partial y_o^4(N)}{\partial \sigma_{ij}} = w_{ko}^4 \left\{ \frac{\partial y_k^3}{\partial net_k^3} \frac{\partial net_k^3}{\partial y_j^2} \frac{\partial y_j^2}{\partial \sigma_{ij}} \right\} = w_{ko}^4 \frac{\partial y_j^2}{\partial \sigma_{ij}} \\
 &< w_{ko}^4 \left\{ \max \left(\frac{\partial y_j^2}{\partial \sigma_{ij}} \right) \right\} = w_{ko}^4 \left\{ \max \left[\left(\frac{\partial y_j^2}{\partial net_j^2} \frac{\partial net_j^2}{\partial \sigma_{ij}} \right) \right] \right\} \\
 &= w_{ko}^4 \left\{ \max \left[\left(\frac{2}{\sigma_{ij}} \right) \left(\frac{x_i^2 - m_{ij}}{\sigma_{ij}} \right)^2 \exp \left[- \left(\frac{x_i^2 - m_{ij}}{\sigma_{ij}} \right)^2 \right] \right] \right\} \\
 &< w_{ko}^4 \left\{ \max \left(\frac{2}{\sigma_{ij}} \right) \right\} = w_{ko}^4 \left(\frac{2}{\sigma_{ij \min}} \right)
 \end{aligned} \tag{68}$$

因此

$$\|P_\sigma(N)\| < \sqrt{R_u} |w_{ko \max}^4| (2/\sigma_{ij \min}) \tag{69}$$

誤差關係可表示成

$$e(N+1) = e(N) + \Delta e(N) = e(N) + \left[\frac{\partial e(N)}{\partial \sigma_{ij}} \right]^T \Delta \sigma_{ij} \tag{70}$$

其中代表歸屬層的高斯函數 度變化，透過利用(45), (51)以及(70),

可得到

$$\frac{\partial e(N)}{\partial \sigma_{ij}} = \frac{\partial e(N)}{\partial y_o^4} \frac{\partial y_o^4}{\partial \sigma_{ij}} = -\frac{\delta_o^4}{e(N)} P_\sigma(N) \tag{71}$$

$$e(N+1) = e(N) - \left[\frac{\delta_o^4}{e(N)} P_\sigma(N) \right]^T \eta_\sigma \delta_o^4 P_\sigma(N) \tag{72}$$

因此

$$\begin{aligned} \|e(N+1)\| &= \left\| e(N) \left[1 - \eta_\sigma \left(\frac{\delta_o^4}{e(N)} \right)^2 P_\sigma^T(N) P_\sigma(N) \right] \right\| \\ &\leq \|e(N)\| \left\| 1 - \eta_\sigma \left(\frac{\delta_o^4}{e(N)} \right)^2 P_\sigma^T(N) P_\sigma(N) \right\| \end{aligned} \quad (73)$$

假設 η_σ 選擇為 $\eta_\sigma = \lambda / (P_{\sigma \max}^2) = \eta_w [w_{k\max}^4 / (2/\sigma_{ij\min})]^2$ ，則 (73) 中的

$\left\| 1 - \eta_\sigma (\delta_o^4 / e(N))^2 P_\sigma^T(N) P_\sigma(N) \right\|$ 將小於 1。因此 普 函數可透過

(56)與(57)得到 $V > 0$ 以及 $\Delta V < 0$ 之結果可證明穩定度，估測負載與實際負載的輸出誤差在時間趨近於無 大的時候將可收斂到 0，這個結果完全符合所提出的第二個理論。

(三) 粒子群優化演算法介紹

粒子群優化演算法(Particle Swarm Optimization, PSO)又可稱為為粒子群演算法、微粒群演算法、或微粒群優化演算法，是通過模擬 群覓 行為而發展起來的一種基於群體協作的隨機 索演算法，通常 為它是群集智能(Swarm Intelligence, SI)的一種，它可以被納入多主體優化系統 (Multiagent Optimization System, MAOS)，是由 Eberhart 和 Kennedy 所發明。

PSO 模擬 群的 行為：一群 在隨機 索 物，在這個區域 只有一 物，所有的 都不知道 物在那 ，但是他們知道當前的位置離 物還有多遠，那 找到 物的最優策略是

最簡單有效的就是 尋目前離 物最近的 的周圍區域。PSO 從這種模型中得到啟示並用於解決優化問題，PSO 中，每個優化問題的解都是 索空間中的一 ，其稱之為「粒子」，所有的粒子都有一個由被優化的函數決定的適應值(Fitness Value)，每個粒子還有一個速度決定他們 的方向和距離，然後粒子們就 隨當前的最優粒子在解空間中 索。

粒子群優化演算法 化為一群隨機粒子(隨機解)，然後通過代找到最優解，在每一 代中，粒子通過跟 兩個「極值」來更新自 ，第一個就是粒子本身所找到的最優解，這個解 做個體極值(pbest)，另一個極值是整個 群目前找到的最優解，這個極值是全域極值(gbest)。另外也可以不用整個種群而只是用其中一部分最佳粒子的鄰 ，那 在所有鄰 中的極值就是局部極值，當找到這兩個極值時，粒子根據如下之式子更新本身速度和位置：

$$V_{id}(t+1) = V_{id}(t) \times w + c_1 \times \text{rand}(\cdot) \times [p_{pbest}(t) - x_{id}(t)] + c_2 \times \text{rand}(\cdot) \times [p_{gbest}(t) - x_{id}(t)] \quad (74)$$

$$x_{id}(t+1) = x_{id}(t) + V_{id}(t+1) \quad (75)$$

其中 x_{id} 為粒子位置， V_{id} 為粒子速度， t 為 代 數， p_{pbest} 為局部極值， p_{gbest} 為全域極值， $\text{rand}(\cdot)$ 為介於0至1間之隨機變數， w 為 性權重值， c_1 及 c_2 為正值加速係數。整個粒子群優化演算法設計流程可以整理為下列步驟：

1. 評估每一個粒子的適應函數值。
2. 適應函數值與粒子本身的最佳函數值記憶比較，而粒子依照個體最佳變數記憶去修正下一 變數 尋的粒子速度。
3. 個體最佳函數值與群體最佳函數值的最佳化程度做比較，如個體最佳優於群體最佳值，則修正群體最佳函數值的變數記憶，同時每個粒子依照群體最佳變數記憶來修正下一 變數 尋的粒子速度。
4. 利用隨機的方式產生出粒子的位置與速度更新值。
5. 利用式子(74)和(75)來改變粒子的位置與速度。
6. 若滿足 條件就中 運作，否則重複步驟 2~5。

與先前所提到常見的演算法做比較，粒子群優化演算法優勢在於計算成本低、簡單容易實現並且沒有許多參數需要調整，以粒子群優化演算法與傳統基因演算法做比較，可發現粒子群優化演算法的資訊共用機制是很不同的，在基因演算法中，染色體互相共用資訊，所以整個種群的移動式比較均 的向最優區移動，在粒子群優化演算法中，只有 gbest(或 pbest)資訊給其他粒子，這是單向的資訊流動，整個 索更新過程是跟隨當前最優解的過程，與基因演算法比較，在大多數情況下，所有粒子可能更快的收斂於最佳解。

(四) 建立用電需量估測架構

本計畫在此共提出了五種估測架構：類神經網路(Neural Network, NN)搭配倒傳遞(Back-propagation, BP)演算法(NN-BP)架構、模糊類

神經網路(Fuzzy Neural Network, FNN)搭配倒傳遞演算法(FNN-BP)架構、模糊類神經網路搭配倒傳遞演算法以及可變學習速率(FNN-BP-V)架構、模糊類神經網路搭配粒子群優化(Particle Swarm Optimization, PSO)演算法(FNN-PSO)架構與粒子群優化演算(PSO)架構，未來將透過數值模擬驗證各種模型之估測效果。

用電需量估測模型通常都是利用過去歷史的負載資料、氣候至是估測廠址的人口數等詳細資料做為估測模型之歷史資訊，而本計畫所提出之用電需量估測模型，其單純只需要利用估測廠址之過去歷史的負載資料即可達到估測之目的，不但架構較為簡單，也減少了許多資訊收集的硬體設備。

以短期用電需量的歷史資訊選取來說，一般估測下一小時的用電需量時，通常會選擇最近可取得的資料，例如一天同一小時的用電資料等。在過去的文獻當中，有研究提出選擇利用距離估測時間最近的資料當作輸入資訊，但這種選取方法不足以呈現估測時間的特徵，為了改善估測的精確度，一個相似時間負載變化選取法被提出作為短期需量估測模型的歷史資訊選取方式。

在負載系統中由於受到社會活動等關係，因此負載估測時間是期幾是一個很重要的參考資訊，另外估測時間是一天中的第幾個小時也同樣是很重要的參考資訊，因為一天與一小時上的負載特徵有很大的差距，此外，突然的負載變動也對估測結果有很大的影響，

為了防 估測精確度受到突然用電 的變化而下降，因此離估測時間最近的負載資料也必須考慮做為其歷史資訊。

根據上述所提到的情況，本計畫所提出之短期需量估測模型包含三個歷史資訊，其包括 天跟估測小時同一小時的負載變化資訊、上 期同一天跟估測小時同一小時的負載變化資訊以及兩 期前同一天跟估測小時同一小時的負載變化資訊，短期用電需量估測模型之歷史資訊可分別表示為式子(76)-(78)。

以中長期需量的歷史資訊選取來說，一般估測明天或下個月的用電需量時，通常會選擇最近可取得的資料，例如上 期同一天的用電資料或是上一年同一個月等。在此同樣利用一相似時間負載變化選取法被提出作為中長期需量估測模型的歷史資訊選取方式，以中期用電需量估測模型之歷史資訊選取主要是包括 天負載變化資訊、上 期的同一天負載變化資訊與兩 期前之同一天負載變化資訊，而長期用電需量估測模型之歷史資訊則是包括了上一個月負載變化資訊、上一年同一個月負載變化資訊以及兩年前同一個月負載變化資訊，中期與長期用電需量估測模型之歷史資訊可分別表示為式子(79)-(81)與式子(82)-(84)。

短期用電需量估測模型歷史資訊

$$x_1^s = [x_l^s(t^s - 24) - x_l^s(t^s - 25)] / x_l^s(t^s - 25) \quad (76)$$

$$x_2^s = [x_l^s(t^s - 168) - x_l^s(t^s - 169)] / x_l^s(t^s - 169) \quad (77)$$

$$x_3^s = [x_l^s(t^s - 336) - x_l^s(t^s - 337)] / x_l^s(t^s - 337) \quad (78)$$

其中 t^s 為目前小時數， x_l^s 為小時負載需量。

中期用電需量估測模型歷史資訊

$$x_1^m = [x_l^m(t^m - 1) - x_l^m(t^m - 2)] / x_l^m(t^m - 2) \quad (79)$$

$$x_2^m = [x_l^m(t^m - 7) - x_l^m(t^m - 8)] / x_l^m(t^m - 8) \quad (80)$$

$$x_3^m = [x_l^m(t^m - 14) - x_l^m(t^m - 15)] / x_l^m(t^m - 15) \quad (81)$$

其中 t^m 為目前天數， x_l^m 為一天負載需量。

長期用電需量估測模型歷史資訊

$$x_1^h = [x_l^h(t^h - 1) - x_l^h(t^h - 2)] / x_l^h(t^h - 2) \quad (82)$$

$$x_2^h = [x_l^h(t^h - 12) - x_l^h(t^h - 13)] / x_l^h(t^h - 13) \quad (83)$$

$$x_3^h = [x_l^h(t^h - 24) - x_l^h(t^h - 25)] / x_l^h(t^h - 25) \quad (84)$$

其中 t^h 為目前月份， x_l^h 為月份負載需量。本計畫所提出之用電需量

負載估測系統主要目的是估測 $x_l^{idx}(t^{idx} - 1) \Big|_{idx=s,m,h}$ 與 $x_l^{idx}(t^{idx}) \Big|_{idx=s,m,h}$ 之間

的變化率，因此估測的負載 $x_f^{idx}(t^{idx}) \Big|_{idx=s,m,h}$ 可表示為

$$x_f^{idx}(t^{idx}) = (1 + y^{idx}) x_l^{idx}(t^{idx} - 1), \quad idx = s, m, h \quad (85)$$

其中上標「idx」代表短期(s)、中期(m)或長期(h)估測所對應數量值，

$y^{idx} \Big|_{idx=s,m,h}$ 代表估測系統所估測之負載變化率， $x_f^{idx}(t^{idx}) \Big|_{idx=s,m,h}$ 與

$x_l^{idx}(t^{idx}) \Big|_{idx=s,m,h}$ 之間的誤差即為輸出誤差，其將連續的計算並更新估

測系統之參數，而本計畫所提出的模型也將透過數值模擬驗證其效果。

1. NN-BP架構

在此是將類神經網路與傳統倒傳遞演算法做結合，在估測用電需量時藉由所挑選之歷史資訊(76)-(78)、(79)-(81)及(82)-(84)分別做為類神經網路之短期、中期及長期估測輸入資訊，之後經過類神經網路運算後輸出負載之變化率 $y^{idx} \Big|_{idx=s,m,h}$ ，接著透過式子(85)計算出所估測之負載 $x_f^{idx}(t^{idx}) \Big|_{idx=s,m,h}$ 並與實際負載做比較，所計算出之誤差不斷透過倒傳遞演算法更新類神經網路之權重值，以達到估測之目標。

2. FNN-BP架構

在此是將模糊類神經網路與傳統倒傳遞演算法做結合，在估測用電需量時藉由所挑選之歷史資訊(76)-(78)、(79)-(81)及(82)-(84)分別做為模糊類神經網路之短期、中期及長期估測輸入資訊，之後經過模糊類神經網路運算輸出負載之變化率 $y^{idx} \Big|_{idx=s,m,h}$ ，接著透過式子(85)計算出所估測之負載 $x_f^{idx}(t^{idx}) \Big|_{idx=s,m,h}$ 並與實際負載做比較，所計算出之誤差不斷透過倒傳遞演算法更新模糊類神經網路之中心點、度與權重值，以達到估測之目標。

3. FNN-BP-V架構

在此是將模糊類神經網路與傳統倒傳遞演算法做結合，此外還加入了可變學習速率之調整，期望達到更好的估測結果，在估測用電需量時藉由所挑選之歷史資訊(76)-(78)、(79)-(81)及(82)-(84)分別做為模糊類神經網路之輸入資訊，之後經過模糊類神經網路運算輸出負載之變化率 $y^{idx} \Big|_{idx=s,m,h}$ ，接著透過式子(85)計算出所估測之負載 $x_f^{idx}(t^{idx}) \Big|_{idx=s,m,h}$ 並與實際負載做比較，所計算出之誤差不斷透過倒傳遞演算法更新模糊類神經網路之中心點、度、學習速率與權重值，以達到估測之目標。

4. FNN-PSO架構

在此是將模糊類神經網路與粒子群優化演算法做結合，粒子群優化演算法的粒子包含了模糊類神經網路之中心點、度與權重值，在估測用電需量時藉由所挑選之歷史資訊(76)-(78)、(79)-(81)及(82)-(84)分別做為模糊類神經網路之輸入資訊，之後經過模糊類神經網路運算輸出負載之變化率 $y^{idx} \Big|_{idx=s,m,h}$ ，接著透過式子(85)計算出所估測之負載 $x_f^{idx}(t^{idx}) \Big|_{idx=s,m,h}$ 並與實際負載做比較，透過計算出之誤差作為適應函數值來評斷粒子優程度，接著找出局部最佳解(pbest)與全域最佳解(gbest)不斷更新粒子之速度與位置，找到最佳之模糊類

神經網路之參數以達到估測之目標。

5. PSO架構

在此是提出單純以粒子群優化演算法作為估測架構，粒子群優化演算法粒子就代表了所要估測之負載變化率，在估測用電需量時藉由所挑選之(76)-(78)、(79)-(81)及(82)-(84)分別作為其歷史資訊，之後經過粒子群優化演算法架構演化輸出負載變化率 $y^{idx} \Big|_{idx=s,m,h}$ ，接著透過式子(85)計算出所估測之負載 $x_f^{idx}(t^{idx}) \Big|_{idx=s,m,h}$ 並與實際負載做比較，透過計算出之誤差作為適應函數值來評斷粒子優 程度，接著找出局部最佳解(pbest)與全域最佳解(gbest)不斷更新粒子之速度與位置，找到最佳之負載變化率以達到估測之目標。

在完成以模糊神經網路以及粒子群優化演算法為基礎之智慧型估測架構與短期、中期以及長期估測模型後，接下來將利用元智大學電力管理及控制系統之實際負載資料做數值模擬，驗證所提出之智慧型估測架構之實際效能。

(五) 數值模擬

在此將測試所提出之粒子群優化(Particle Swarm Optimization, PSO)演算法架構之用電需量估測之效能，並與上述所提到之類神經網路(Neural Network, NN)搭配倒傳遞(Back-propagation, BP)演算法(NN-BP)架構、模糊類神經網路(Fuzzy Neural Network, FNN)搭配倒

傳遞演算法(FNN-BP)架構、模糊類神經網路搭配倒傳遞演算法以及可變學習速率(FNN-BP-V)架構及模糊類神經網路搭配粒子群優化演算法(FNN-PSO)架構做比較。

在此習用類神經網路是如同先前所提到的輸入層包含三個輸入因子、 n^{idx} 層包含 n^{idx} 個神經元以及單一輸出之架構，而其學習率定在 0.5，而模糊類神經網路之架構也如先前提到的輸入層包含三個輸入因子、歸屬函數層包含 n^{idx} 個神經元、規則層包含二十七的神經元及單一輸出之架構，在 FNN-BP 架構中其學習率定在 0.5；在 FNN-BP-V 架構中，學習率是根據先前內容提到的理論 1 與理論 2 做自動調整；有關 FNN-PSO 中 PSO 調整演算法參數選取主要是有 30 個粒子、 c_1 及 c_2 選擇為 1.5 以及 w 性權重選擇為 0.05，而在 PSO 架構中的參數選取包括 30 個粒子、 c_1 及 c_2 選擇為 0.5 以及 w 性權重選擇為 0.65，其適應函數值簡單選取為估測誤差之絕對值。

本計畫所提出之用電需量負載估測系統是透過平均絕對值誤差 (Mean Absolute Percentage Error, MAPE)來評斷估測精確度，其判斷式可表示如下：

$$MAPE^{idx} = \frac{1}{n^{idx}} \sum_{t^{idx}=t_{st}^{idx}}^{t_{st}^{idx}+n^{idx}} \left[\frac{|x_f^{idx}(t^{idx}) - x_l^{idx}(t^{idx})|}{x_l^{idx}(t^{idx})} \right] \times 100\% \quad (86)$$

其中上標「 idx 」代表短期(s)、中期(m)或長期(h)估測所對應數量值， t_{st}^{idx} 是第一待估測負載資料數編號以及 n^{idx} 是估測負載的數量，在此

是利用元智大學電力監控系統的實際資料做模擬測試，短期需量估測部分主要是估測下一小時之需量，在此隨機挑選元智大學 2009 年 3 月 10 號、5 月 12 號、8 月 3 號以及 11 月 2 號的資料做測試，NN-BP、FNN-BP、FNN-BP-V、FNN-PSO 及 PSO 估測模擬結果如圖 36 至圖 40 所示，其中圖 36 到圖 40 內的各小圖說明如下：(a) 2009 年 3 月 10 號的估測結果；(b) 2009 年 5 月 12 號的估測結果；(c) 2009 年 8 月 3 號的估測結果；(d) 2009 年 11 月 2 號的估測結果，而圖 41 至圖 44 則是將各種估測架構之估測結果做一個比較。

在中期需量估測部分主要是估測下一天之需量，在此隨機挑選元智大學 2009 年 3 月、9 月、10 月以及 11 月整個月的資料做測試，其模擬結果如圖 45 至圖 49 所示，其中圖 42 到圖 46 內的各小圖說明如下：(a) 2009 年 5 月份的估測結果；(b) 2009 年 9 月份的估測結果；(c) 2009 年 10 月份的估測結果；(d) 2009 年 11 月份的估測結果，而圖 50 至圖 53 則是將各種估測架構之中期需量估測結果做一個比較。在長期需量估測部分主要是估測下一個月之需量，在此利用 2009 年整年做為測試，其模擬結果如圖 54 所示，各小圖說明如下：(a) NN-BP 的估測結果；(b) FNN-BP 的估測結果；(c) FNN-BP-V 的估測結果；(d) FNN-PSO 的估測結果；(e) PSO 架構的估測結果，圖 55 則是將所有估測架構之估測結果做一個比較。

根據數值模擬結果可將各種用電需量估測架構之 MAPE 整理如

表格 19-21 所示，從數值模擬結果可得知所提出之粒子群優化(PSO)演算法估測架構運用在短期、中期及長期用電需量估測時，其 MAPE 值大約可在 2%、4%與 6%以內，此外所提出之 PSO 估測架構在短期、中期與長期用電需量估測中，對於 NN-BP 估測架構其改善率可達 28.3%以上，最高可達到 57.7%，對於 FNN-BP 估測架構其改善率可達 26.1%以上，最高可達到 52.9%，對於 FNN-BP-V 估測架構其改善率可達 18.4%以上，最高可達到 48.2%，對於 FNN-PSO 估測架構其改善率可達 4.4%以上，最高可達到 18.9%，驗證所提出之 PSO 估測架構其實用性與估測效能。此外，為了驗證本計畫所提出之 PSO 估測架構其運算效率，在此將與其 四種估測架構針對運算時間做比較，其結果整理如表格 22 所示，從結果可得知本研究所提出之 PSO 估測架構在短期、中期與長期用電需量估測中，對於 NN-BP 估測架構其運算時間改善率平均約可達到 17.39%、19.1%以及 12.3%，對於 FNN-BP 估測架構其運算時間改善率平均約可達到 22%、24.5%以及 31%，對於 FNN-BP-V 估測架構其運算時間改善率平均約可達到 23.8%、26.1%以及 33.3%，對於 FNN-PSO 估測架構其運算時間改善率平均約可達到 42.9%、46.9%以及 47.1%，驗證所提出之 PSO 估測架構運算效率優於其 四種估測架構。

表格 19 各種短期需量估測架構之 MAPE 值

估測架構	3/10	5/12	8/3	11/2	平均
------	------	------	-----	------	----

NN-BP	3.63%	4.17%	4.2%	3.92%	3.98%
FNN-BP	3.26%	3.95%	4.11%	3.62%	3.74%
FNN-BP-V	3.08%	3.77%	3.52%	3.22%	3.4%
FNN-PSO	1.85%	2.1%	2.34%	2.38%	2.17%
PSO	1.62%	1.64%	1.94%	1.84%	1.76%

表格 20 各種中期需量估測架構運用於各月份之 MAPE 值

估測架構	三月	月	十月	十一月	平均
NN-BP	6.43%	4.74%	5.25%	4.06%	5.12%
FNN-BP	6.38%	4.58%	5.22%	3.93%	4.97%
FNN-BP-V	5.91%	4.26%	4.37%	3.79%	4.5%
FNN-PSO	4.34%	3.73%	4.26%	3.68%	4%
PSO	3.98%	3.61%	3.67%	3.43%	3.67%

表格 21 各種長期需量估測架構運用於整年之 MAPE 值

估測架構	PSO Structure	FNN-PSO	FNN-BP-V	FNN-BP	NN-BP
2009 年	5.9%	6.17%	10.64%	11.04%	13.95%

表格 22 各種估測架構運用於各種估測模型之運算時間

估測架構	短期需量估測	中期需量估測	長期需量估測
NN-BP	0.6043(s)	0.6552(s)	0.3558(s)
FNN-BP	0.6396(s)	0.702(s)	0.4524(s)
FNN-BP-V	0.6552(s)	0.7176(s)	0.468(s)
FNN-PSO	0.8736(s)	0.9984(s)	0.5928(s)
PSO	0.4992(s)	0.53(s)	0.312(s)

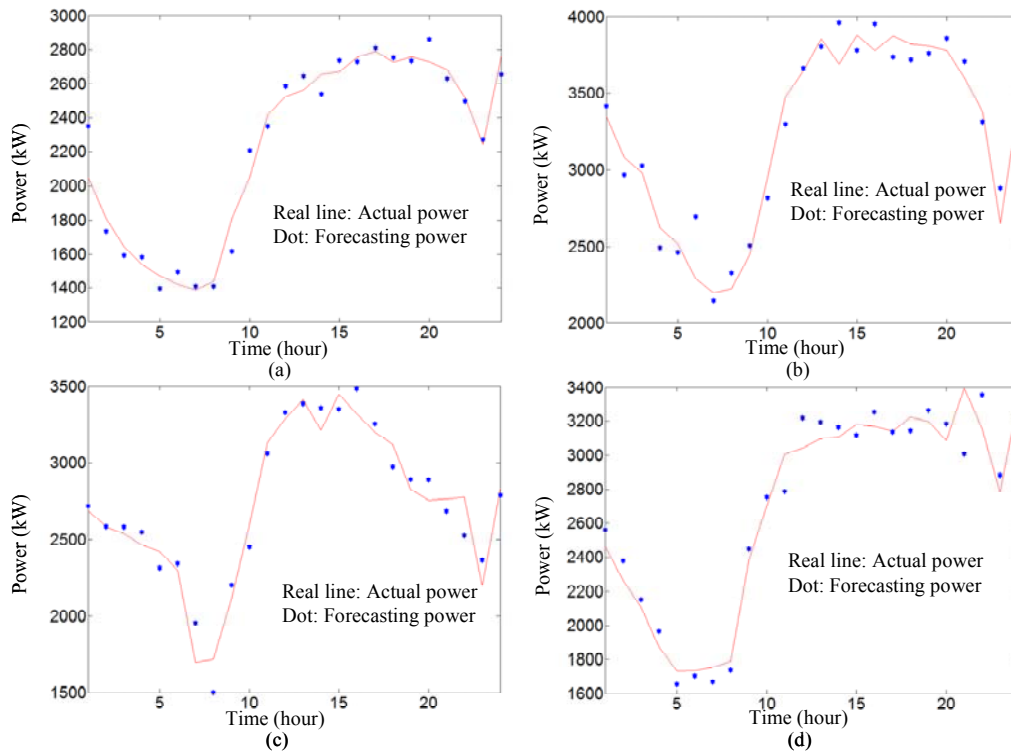


圖36 NN-BP運用於短期需量負載估測結果

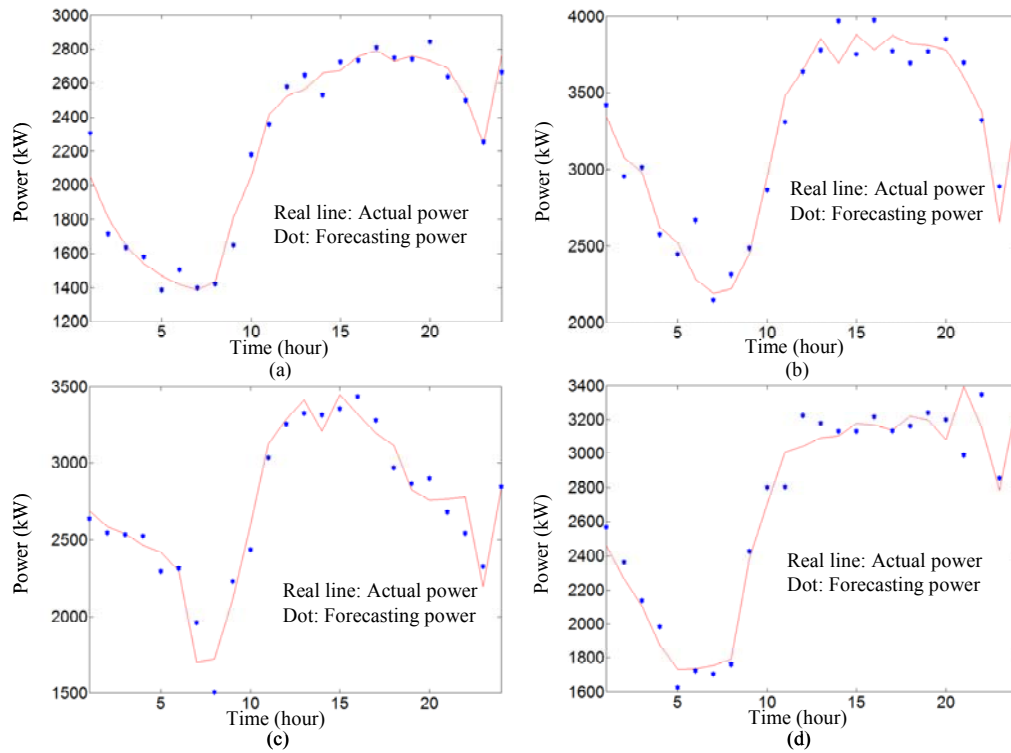


圖37 FNN-BP運用於短期需量負載估測結果

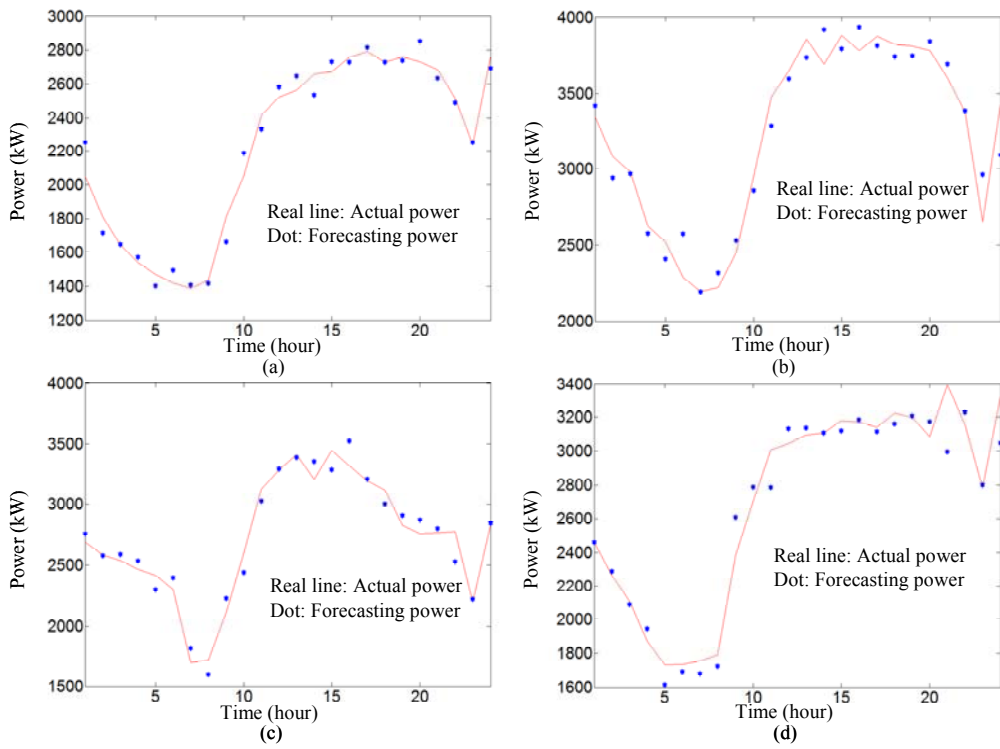


圖38 FNN-BP-V運用於短期需量負載估測結果

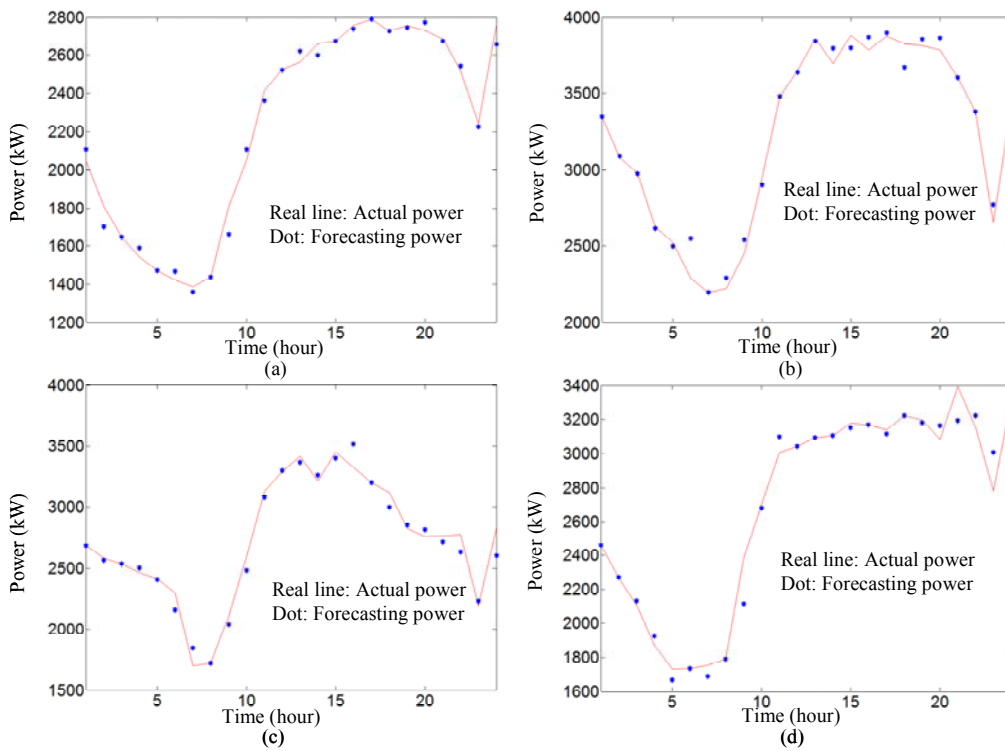


圖39 FNN-PSO運用於短期需量負載估測結果

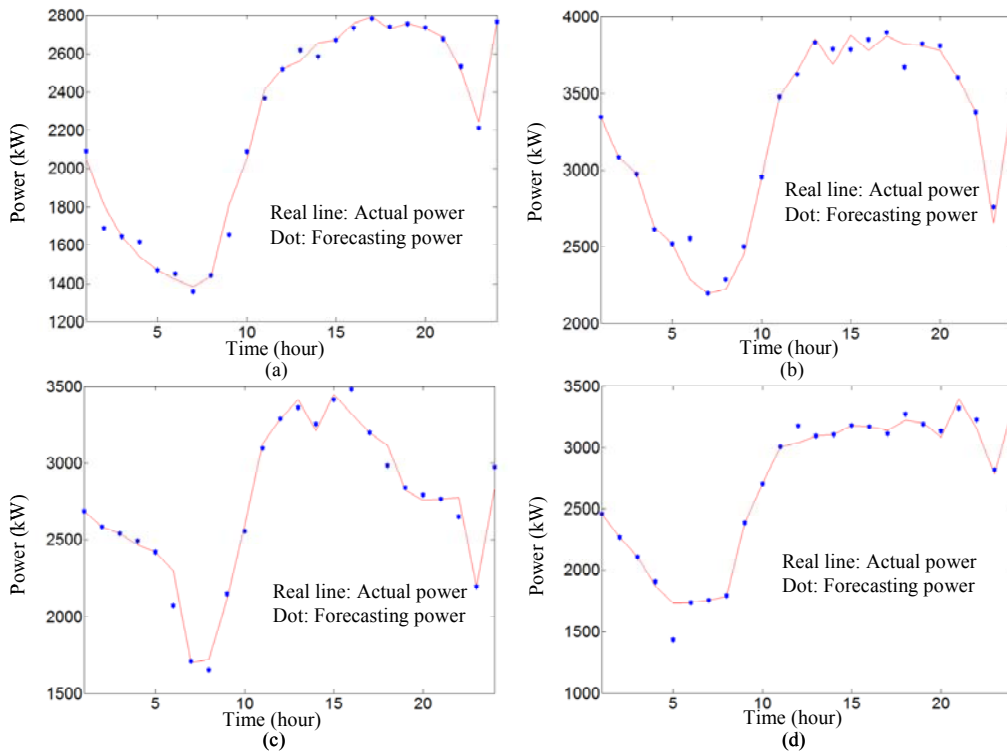


圖40 PSO架構運用於短期需量負載估測結果




圖41 各種估測架構運用於2009年3月10號之短期需量估測結果




圖42 各種估測架構運用於2009年5月12號之短期需量估測結果




圖43 各種估測架構運用於2009年8月3號之短期需量估測結果




圖44 各種估測架構運用於2009年11月2號之短期需量估測結果

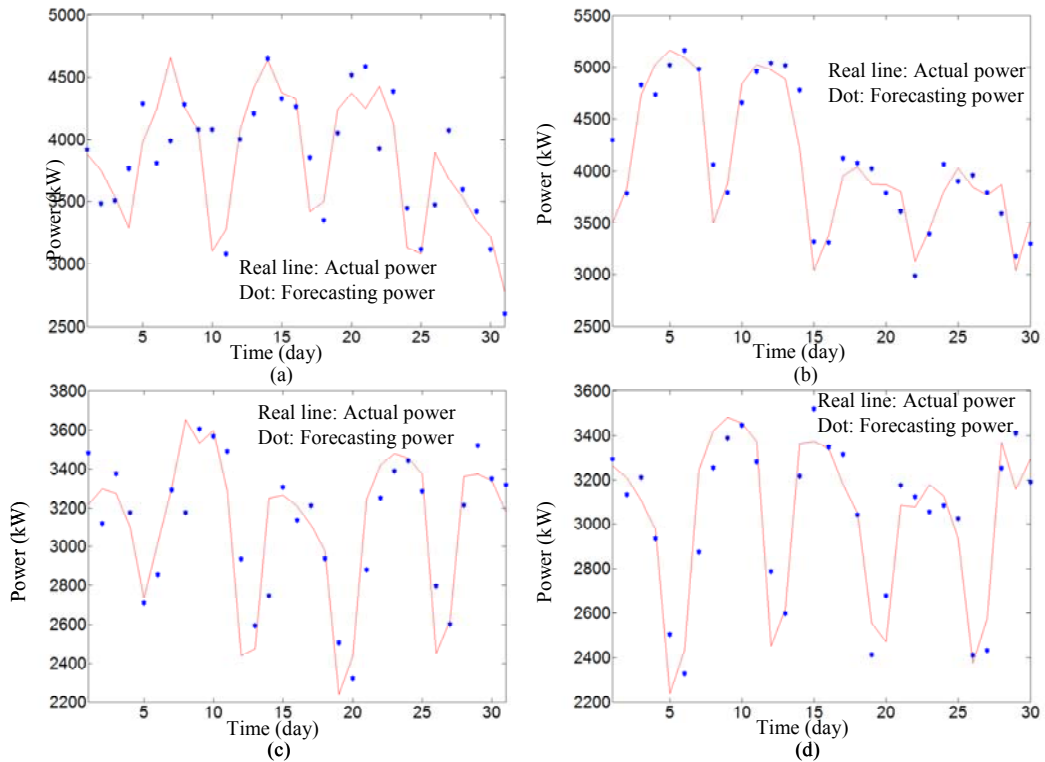


圖45 NN-BP運用於中期需量負載估測結果

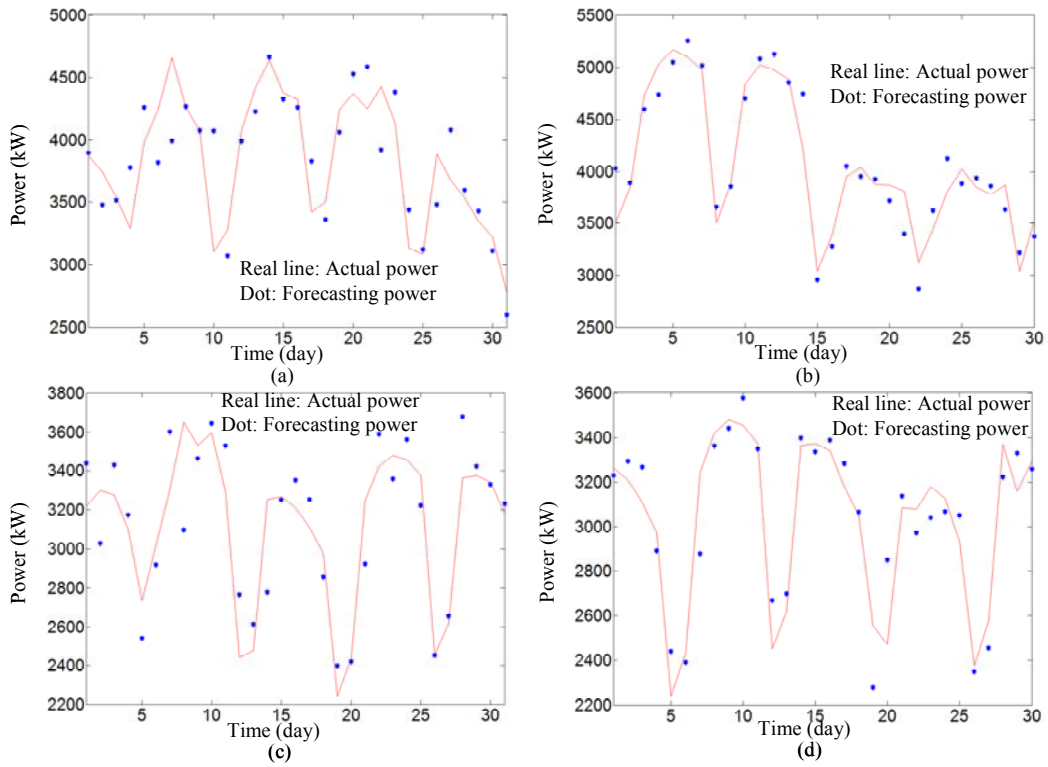


圖46 FNN-BP運用於中期需量負載估測結果

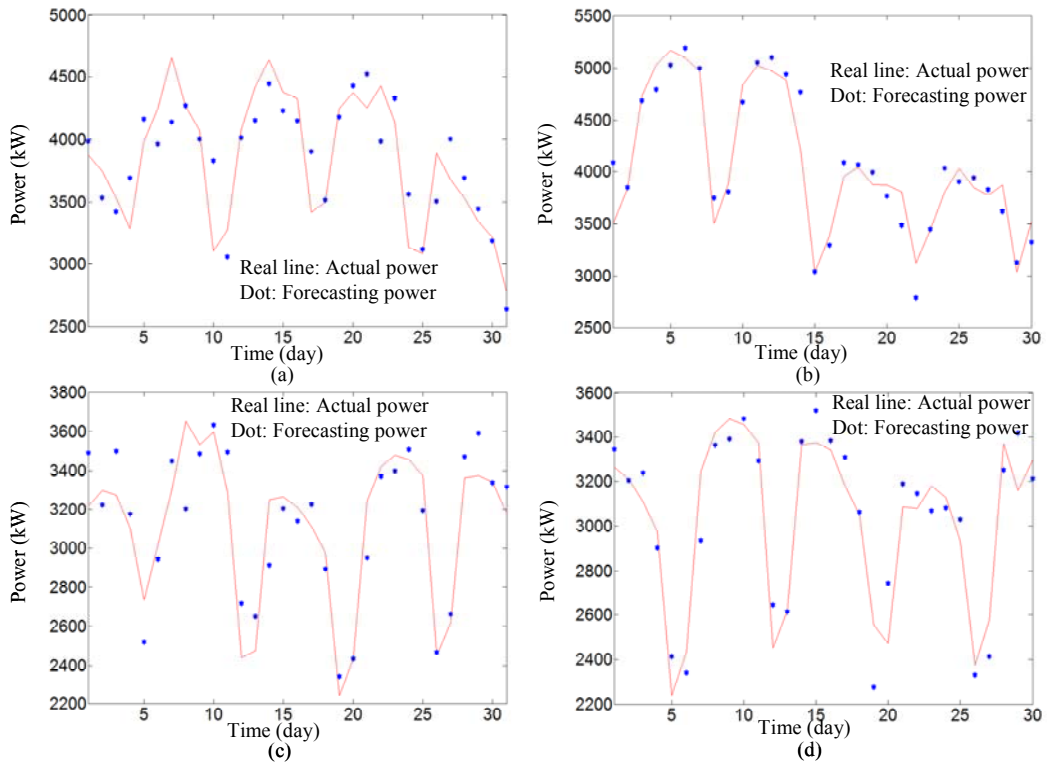


圖47 FNN-BP-V運用於中期需量負載估測結果

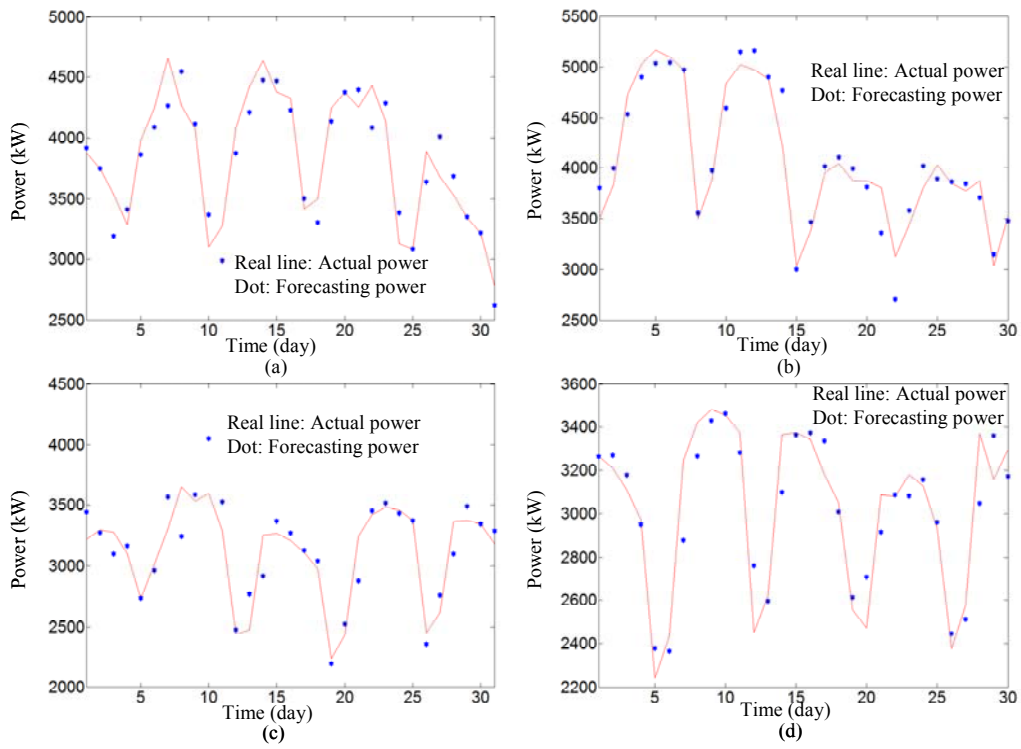


圖48 FNN-PSO運用於中期需量負載估測結果

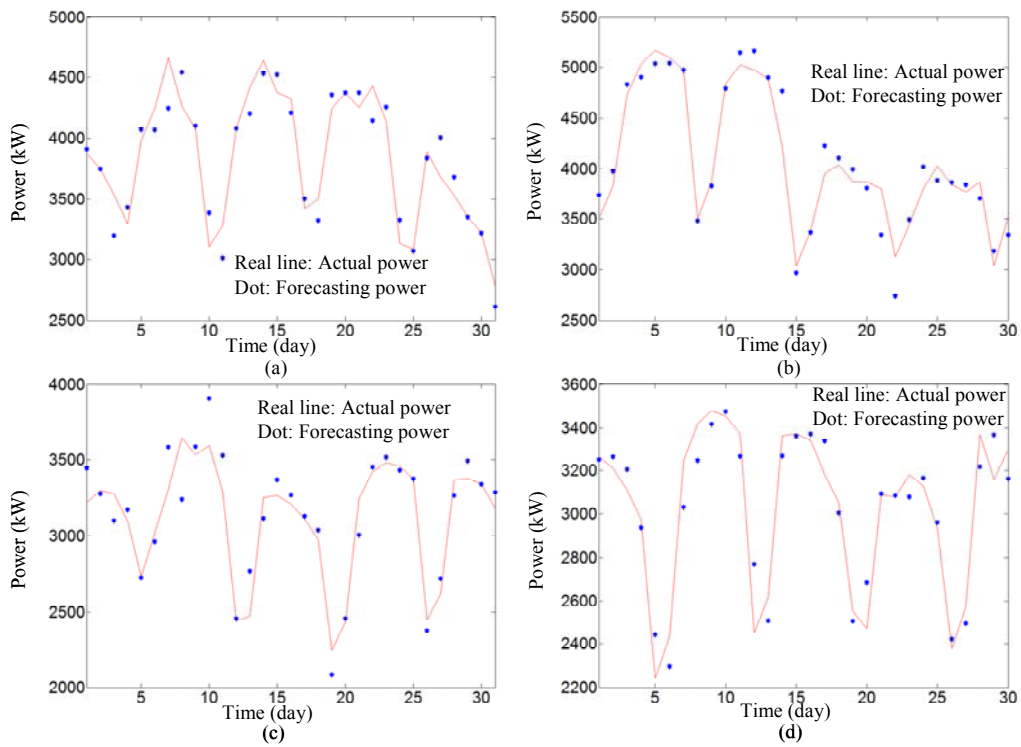


圖49 PSO架構運用於中期需量負載估測結果




圖50 各種估測架構運用於2009年3月之中期需量估測結果

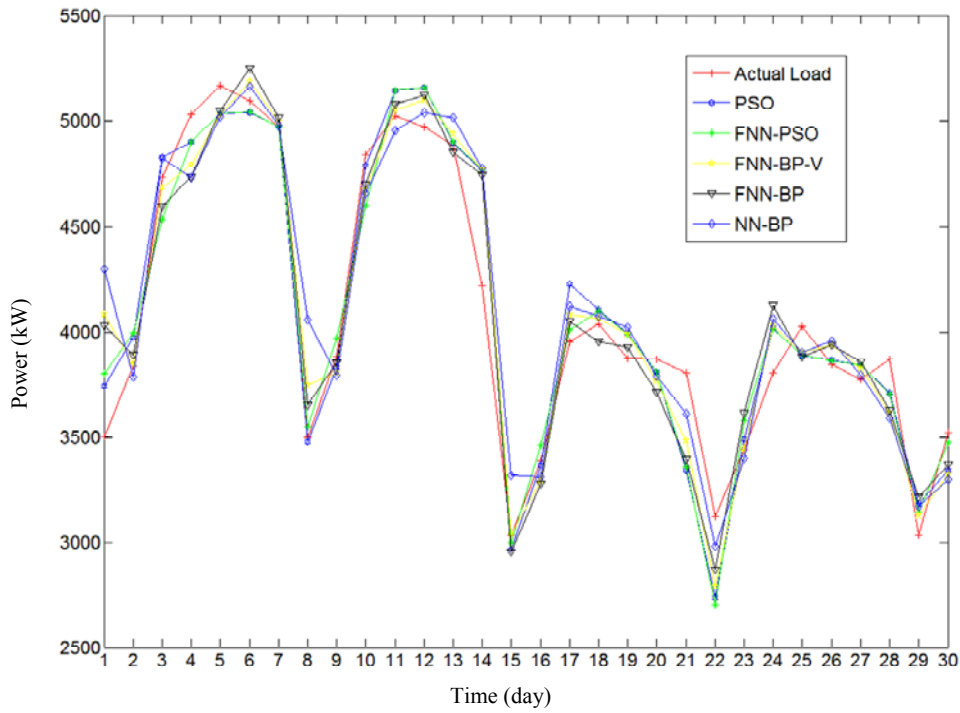


圖51 各種估測架構運用於2009年9月之中期需量估測結果




圖52 各種估測架構運用於2009年10月之中期需量估測結果




圖53 各種估測架構運用於2009年11月之中期需量估測結果

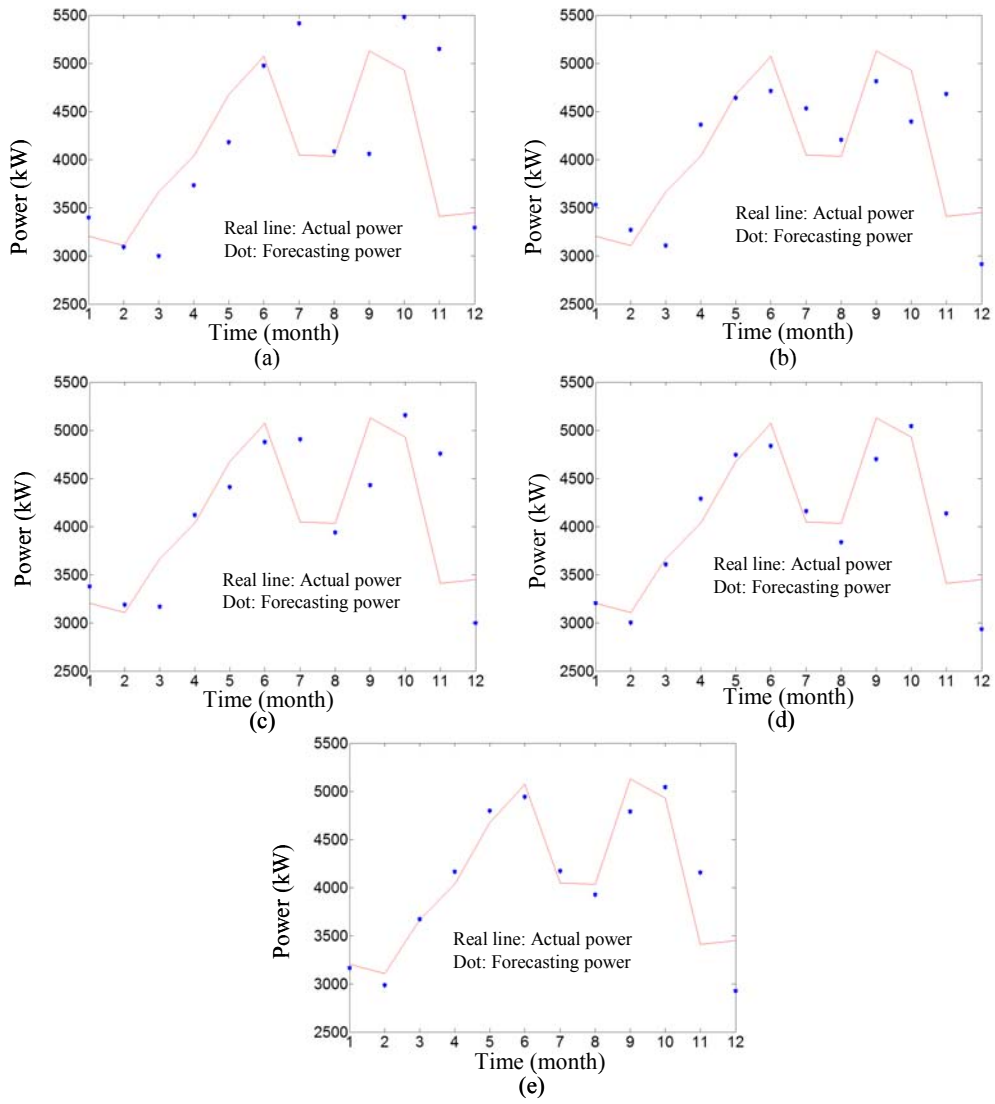


圖54 各種估測架構運用於2009年之長期需量估測結果




圖55 各種估測架構運用於2009年之長期需量估測結果

參、主要發現與結論

本計畫「智慧型微型電網最佳化用電需量與能源配置比例估測機制」成功發展出一混合能源發電系統裝置容量最佳化機制以及智慧型估測架構，其可決定智慧型微型電網所供應特定負載之用電需量以及系統內部各種能源之配置比例，使其能夠同時達到最佳經濟效益與用電效率。

本計畫所提出之混合能源發電系統裝置容量最佳化設計可運用範圍相當廣，其主要用電可分成自用電以及配合電力公司收購再生能源之政策，若選擇自用電，其可根據設置場址預期達到目標之不同去設計其混合能源發電系統，若設置場址裝置此混合能源發電系統主要目標為預期可達到抑制超約用電以超約罰款之目標，其主要利用過去用電資料找出最大超約用電量，利用此混合能源系統提供最大超約用電量以罰款，或者設置場址目標為一年內可節約預期電量，便將預期所節約之電量做為此混合能源之總裝置容量，以達到每年預期節約電量之目標，在選擇自用電部分主要就可依設置場址不同之情境設計其混合能源發電系統之總裝置容量。若選擇配合電力公司收購再生能源，則可根據使用者預期獲利設置混合能源系統之總裝置容量，本計畫所提出之混合能源發電系統裝置容量最佳化機制可適用於上述各種情境，依設置場址之不同需求做最貼切設計，以達到最佳之經濟效益。

此外，本計畫還提出一短期、中期與長期用電需量估測模型，並成功發展一粒子群優化(PSO)演算法估測架構，其可適用於各種型態之估測模型，並且實際利用元智大學做測試驗證所提出估測系統之效能，此外，由於在歷史資訊的選取上採用相似時間負載變化選取法，使其估測系統架構更為簡化且大幅降低運算時間，根據數值模擬之結果，可發現所提出之用電需量估測模型搭配粒子群優化(PSO)演算法估測架構比傳統之 NN-BP、FNN-BP、FNN-BP-V 與 FNN-PSO 估測架構都具有更精確之估測效能，在短期、中期與長期用電需量估測中，本計畫所提出之粒子群優化(PSO)演算法估測架構對於 NN-BP 估測架構其改善率可達 28.3%以上，最高可達到 57.7%，對於 FNN-BP 估測架構其改善率可達 26.1%以上，最高可達到 52.9%，對於 FNN-BP-V 估測架構其改善率可達 18.4%以上，最高可達到 48.2%，對於 FNN-PSO 估測架構其改善率可達 4.4%以上，最高可達到 18.9%，此外 PSO 估測架構在短期、中期與長期用電需量估測中，對於 NN-BP 估測架構其運算時間改善率平均約可達到 17.39%、19.1%以及 12.3%，對於 FNN-BP 估測架構其運算時間改善率平均約可達到 22%、24.5%以及 31，對於 FNN-BP-V 估測架構其運算時間改善率平均約可達到 23.8%、26.1%以及 33.3，對於 FNN-PSO 估測架構其運算時間改善率平均約可達到 42.9%、46.9%以及 47.1，驗證所提出之 PSO 估測架構其估測效率。

最後本計畫「智慧型微型電網最佳化用電需量與能源配置比例估測機制」符合以下技術指標(1)單位智慧型用電需量估測所需收斂時間可低於傳統傳遞類神經網路估測系統 10%；(2)短期用電需量估測的平均絕對值誤差率(Mean Absolute Percentage Error)可低於 2%；(3)中期用電需量估測的平均絕對值誤差率可低於 4%；(4)長期用電需量估測的平均絕對值誤差率可低於 6%；(5)建立太陽能光電池與風力發電系統動態數學模型，使其模型發電量與實際系統發電量誤差可低於 3%，並利用此動態數學模型找出容量因子確保供電穩定度以及評估實驗廠址裝置黃金比例；(6)可在設備 損之年限內回收成本。未來可將相關技術轉移至能源管理廠 或是研發單位，更進一步研發提供使用端設置以及使用智慧型電網時可達到最佳經濟效益與用電效率。

肆、參考文獻

1. W. El Khatam and M. M. A. Salama, "Distributed generation technologies, definitions, and benefits," *Electr. Power Syst. Res.*, vol. 71, pp. 119-128, 2004.
2. N. Jenkins, R. Allan, P. Crossley, D. Kirschen, and G. Strbac, *Embedded Generation*. London: The Institution of Electrical Engineers, 2000.
3. H. L. Willis and W. G. Scott, *Distributed Power Generation: Planning and Evaluation*. New York: Marcel Dekker, 2000.
4. E. A. DeMeo, W. Grant, M. R. Milligan, and M. J. Schuerger, "Wind plant integration: costs, status, and issues," *IEEE Power Energy Mag.*, vol. 3, no. 6, pp. 38-46, 2005.
5. C. S. Wang and M. H. Nehrir, "Power management of a stand-alone wind/photovoltaic/fuel cell energy system," *IEEE Trans. Energy Convers.*, vol. 23, no. 3, pp. 957-967, 2008.
6. I. Moghram and S. Rahman, "Analysis and evaluation of five short term load forecasting techniques," *IEEE Trans. Power Syst.*, vol. 4, no.4, pp. 1484-1491, 1989.
7. 進、大全，類神經網路與模糊控制理論入門，全局，2000.

8. 張，機器學習：類神經網路、模糊系統以及基因演算法則，全 局，1999.
9. 宗、英，Fuzzy 控制理論、實作與應用，全 局，1997.
10. F. J. Lin, W. J. Hwang, and R. J. Wai, "A supervisory fuzzy neural network control system for tracking periodic inputs," *IEEE Trans. Fuzzy Systems*, vol. 7, no. 1, pp. 41-52, 1999.
11. 道明，近代控制工程，復文 局，1992.
12. L. X. Wang, *A Course in Fuzzy Systems and Control*. New Jersey: Prentice-Hall, 1997.
13. 成，類神經網路模式應用與實作， 局，1999.
14. F. J. Lin, R. F. Fung, and R. J. Wai, "Comparison of sliding mode and fuzzy neural network control for motor-toggle servomechanism," *IEEE Trans. Mechatronics*, vol. 3, no. 4, pp. 302-318, 1998.
15. R. J. Wai, H. H. Lin, and F. J. Lin, "Hybrid controller using fuzzy neural networks for identification and control of induction servo motor drive," *Neurocomputing*, vol. 35, no. 1-4, pp. 91-112, 2000.
16. E. Gonzalez-Romera, M. A. Jaramillo-Moran, and D. Carmona-Fernandez, "Monthly electric energy demand forecasting with neural networks and Fourier series," *Energy Conversion and*

- Management*, vol. 49, pp. 3135-3142, 2009.
17. Z. A. Bashir and M. E. El-Hawary, "Applying wavelets to short-term load forecasting using PSO-based neural networks," *IEEE Trans. Power Syst.*, vol. 24, no. 1, pp. 20–27, 2009.
 18. M. El-Telbany and F. El-Karmi, "Short-term forecasting of Jordanian electricity demand using particle swarm optimization," *Electr. Power Syst. Res.*, vol. 78, pp. 425–433, 2008.
 19. C. N. Elias and N. D. Hatziargyriou, "An annual midterm energy forecasting model using fuzzy logic," *IEEE Trans. Power Syst.*, vol. 24, no. 1, pp. 469–478, 2009.
 20. J. L. Bernal-Agustin and R. Dufo-Lopez, "Efficient design of hybrid renewable energy systems using evolutionary algorithms," *Energy Conversion and Management*, vol. 50, pp. 479-489, 2009.
 21. 臺灣電力公司，「國風力發電現況與展望」，台電 續產業發展雙月 色能源專輯，第 35 期，第 16 至第 21 頁，2007 年。
 22. J. M. Correa, F. A. Farret, J. R. Gomes, and M. G. Simoes "Simulation of fuel-cell stack using a computer-controlled power rectifier with the purposes of actual high-power injection applications," *IEEE Trans. Ind. Appl.*, vol. 39, no. 4, pp. 1136-1142, 2003.

23. L. F. Wang and C. Singh, "Multicriteria design of hybrid power generation systems based on a modified particle swarm optimization algorithm," *IEEE Trans. Energy Convers.*, vol. 24, no. 1, pp. 163-172, 2009.
24. F. J. Lin, R. J. Wai, and C. C. Lee, "Fuzzy neural network position controller for ultrasonic motor drive using push-pull DC-DC converter," *IEE Proc. Control Theory Appl.*, vol. 146, no. 1, pp. 99–107, 1999.
25. F. J. Lin and R. J. Wai, "Adaptive fuzzy-neural-network control for induction spindle motor drive," *IEEE Trans. Energy Convers.*, vol. 17, no. 4, pp. 507–513, 2002.